

## پیش‌بینی پاسخ آکوستیک، شاخص تردی و سفتی میوه خیار با استفاده از شبکه‌های عصبی مصنوعی

مهدی جهانگیری صالح<sup>۱</sup>، سید رضا حسن بیگی<sup>۲\*</sup>، محمد ابونجمی<sup>۳</sup>، محمود لطفی<sup>۴</sup>

۱- دانشجوی دکتری گروه مهندسی فنی کشاورزی پردیس ابوریحان، دانشگاه تهران

۲- دانشیار گروه مهندسی فنی کشاورزی پردیس ابوریحان، دانشگاه تهران

۳- دانشیار گروه مهندسی فنی کشاورزی پردیس ابوریحان، دانشگاه تهران

۴- دانشیار گروه باغبانی پردیس ابوریحان، دانشگاه تهران

(تاریخ دریافت: ۹۴/۰۸/۱۱ تاریخ پذیرش: ۹۴/۰۹/۱۴)

### چکیده

خیار یک میوه پر مصرف در ایران است که مصرف زیادی در تمام فصول دارد؛ لذا بررسی پارامترهای موثر در میزان کیفیت آن امری اجتناب ناپذیر به نظر می‌رسد. با توجه به صرف هزینه و زمان زیاد برای اندازه‌گیری پارامترها، پیش‌بینی آن‌ها با توجه به عوامل تاثیرگذار بسیار مفیدتر خواهد بود. در تحقیق حاضر ارتباط بین دو ویژگی مکانیکی (شاخص تردی و سفتی) و فشار صدای حاصل از شکستن (پاسخ آکوستیک) میوه خیار با زمان و شرایط مختلف انبارداری و در قسمت‌های مختلف میوه با استفاده از شبکه‌های عصبی مصنوعی مدل‌سازی شد. ورودی شبکه‌ها زمان نگهداری، شرایط نگهداری و موقعیت انجام تست در طول میوه بودند. با استفاده از مقادیر ویژگی‌های مکانیکی و صوتی به عنوان خروجی‌های هدف، شبکه‌های مختلفی با پیکربندیهای متفاوت تعریف و آموزش داده شدند. شبکه عصبی چند لایه پرسپترون و شبکه عصبی با تابع پایه شعاعی با تعداد نرون‌های مختلف و توابع آموزش مومنتوم، گرادیان نزولی و لونبرگ-مارکوارت و توابع آستانه SigmoidAxon و TanhAxon به کار گرفته شدند. دقت یادگیری شبکه‌ها در تخمین ویژگی‌های مکانیکی و صوتی مورد بررسی قرار گرفت. نتایج نشان داد که شبکه عصبی پرسپترون چندلایه با تابع آستانه TanhAxon و تابع آموزش مومنتوم و پیکربندی ۳-۵-۳ بهترین عملکرد در پیش‌بینی فشار صوت، شاخص تردی و سفتی میوه خیار رقم ویولا را دارا بود. شبکه عصبی مذکور توانایی پیش‌بینی فشار صوت، شاخص تردی و سفتی خیار با ضرایب تبیین به ترتیب ۰/۹۹۷۳، ۰/۹۴۵۶ و ۰/۹۱۲۹ و ریشه میانگین مربعات خطای ۰/۰۲۱، ۰/۰۵۲ و ۰/۰۵۹ را داشت.

کلید واژه‌گان: شبکه‌های عصبی مصنوعی، خیار، شاخص تردی، سفتی، فشار صوت، ویولا

\* مسئول مکاتبات: rhbeigi@ut.ac.ir

## ۱- مقدمه

برای قضاوت در مورد کیفیت محصولات غذایی، سبزیجات و میوه‌ها ویژگی‌های بافتی نظیر تردی، سفتی و مدول الاستیسیته دارای کاربردهای فراوانی هستند [۱]. بافت به طور کلی احساسی است که هنگام لمس و جویدن محصول توسط دست، لب، دندان، زبان و گوش ایجاد می‌شود [۲]. در برخی از محصولات از جمله خیار تردی نیز جزء پارامترهای دخیل در تعیین کیفیت است؛ تردی همان صدایی است که هنگام جویدن توسط گوش درک می‌شود [۳]. نحوه آرایش، اتصال سلول‌ها و ترکیبات پکتینی روی خواص بافت تأثیرگذار هستند [۴]. مرسوم‌ترین روش ارزیابی بافت استفاده از دستگاه کشش-فشار مجهز به یک استوانه یا صفحه فشاری است که به وسیله آن محصول تحت فشار قرار می‌گیرد یا سوراخ می‌شود، سپس با تحلیل نمودار نیرو-جابجایی ویژگی‌های مورد نظر استخراج می‌شود [۱، ۵]. سفتی میوه یکی از متغیرهای مرتبط با کیفیت و سنجش غیرمستقیم میزان رسیدگی بوده و ارزیابی دقیق آن، مدت مناسب انبارداری و شرایط بهینه حمل و نقل را میسر می‌سازد [۶]. به غیر از روش‌های مرسوم آزمون‌های مکانیکی، آزمون‌های آکوستیکی یا صوتی به طور فزاینده‌ای برای ارزیابی کیفیت محصولات کشاورزی نظیر میوه‌ها، سبزیجات و فراورده‌ها توسعه یافته‌اند [۷]. آزمون‌های آکوستیکی برای درجه‌بندی محصولات با تعیین رسیدگی یا سفتی میوه‌ها، تردی محصولات، جداسازی تخم‌مرغ‌های شکسته و حتی تعیین محتوای رطوبتی به کار می‌رود. از مزایای آزمون‌های آکوستیکی می‌توان به مدت کوتاه آزمون، سادگی، کم هزینه بودن، تکرار پذیری و غیر تماسی بودن آن اشاره نمود. بر عکس آزمون پانچ یا فشردگی که نمونه‌ها از بافت‌های متمرکز شده در یک نقطه انتخاب می‌شوند؛ اندازه‌گیری صوتی عموماً خصوصیات میوه‌ی کامل را نشان می‌دهد [۸]. میوه و سبزیجات هنگام ترکیدن دیواره سلولی تولید صدا می‌کنند [۹]. فشار آماسیدگی<sup>۱</sup> در تولید این صدا هنگام بارگذاری مکانیکی نقش دارد [۱۰]. چندین روش برای آزمون‌های آکوستیکی جهت بررسی کیفیت میوه‌ها، سبزیجات و محصولات غذایی ارایه شده است که مرسوم‌ترین آن‌ها پاسخ آکوستیک به ضربه می‌باشد. در این روش توسط یک چکش به میوه ضربه زده می‌شود و سیگنال‌های پاسخ آن توسط یک میکروفون یا یک

سنسور پیزوالکتریک ثبت و سپس تحلیل می‌شوند؛ اما این روش مناسب میوه‌های حجیم یا گروی شکل مثل خربزه، هندوانه، سیب و امثال آن می‌باشد [۱۱]. این روش برای ارزیابی سفتی بافت نارنگی در دوران انبارداری و خربزه در دوران رسیدگی استفاده شده است [۸، ۱۲]. ایران با تولیدی حدود سه میلیون تن خیار گلخانه‌ای و زمینی سومین تولید کننده خیار در جهان است و به همراه چین، ترکیه و آمریکا ۶۶ درصد تولید جهانی را به خود اختصاص داده است. در سال زراعی ۱۳۹۲-۱۳۹۱ حدود ۳۵۲ هزار هکتار برابر با ۲/۸۸ درصد از اراضی کشاورزی در ایران زیر کشت محصولات جالیزی بود که سهم خیار زمینی و خیار گلخانه‌ای از آن ۲۷/۵ درصد (حدود ۹۶۸۰۰ هکتار) بود [۱۳]. خیار از نظر سرانه مصرف در بین خانواده‌های ایرانی از جایگاه خاصی برخوردار است. برخی محققان گزارش کرده‌اند که خواص مکانیکی خیار طی دوره نگهداری تغییر می‌کند؛ همچنین این خواص بسته به نوع رقم، روز برداشت و دوره نگهداری متغیر هستند. میوه خیار با بافت سفت‌تر می‌تواند بین ۳-۷ روز قابل مصرف باقی بماند [۱۴، ۱۵]. یوشی‌اکا<sup>۲</sup> و همکاران (۲۰۰۹) چهار روش را برای تفسیر نمودار نیرو-جابجایی میوه خیار به کار گرفتند و به این وسیله کیفیت را بر اساس تردی مورد ارزیابی قرار دادند [۵]. در تحقیقی تفاوت‌های ویژگی‌های بافتی سه رقم خیار را با دو روش آزمون مکانیکی فشار تک محوره و اندازه‌گیری مستقیم نیروی جویدن با استفاده از سنسور ورقه‌ای چند نقطه‌ای<sup>۳</sup> دارای سنسور TSCAN مورد ارزیابی قرار دادند [۱۶]. سفتی بافت چند رقم خیار بومی ایران توسط آزمون پانچ مورد ارزیابی قرار گرفت و اعلام شد که بین ارقام اختلاف معنی‌داری وجود دارد [۱۷، ۱۸]. در تحقیقی گزارش شد که سفتی گوشت پنج برابر بیشتر از تخمدان است و سفتی بافت در قسمت ساقه بیشتر از قسمت گل است [۱۹]. بررسی منابع نشان می‌دهد که اکثر محققان پیشین از آزمون‌های مکانیکی برای بررسی بافت میوه خیار استفاده کرده‌اند؛ اما استفاده از آزمون آکوستیکی تنها به تحقیقی محدود می‌شود که در آن یک میله استوانه‌ای درون بافت میوه خیار نفوذ کرده و همزمان با شکستن بافت میزان ارتعاش توسط یک فیلم پیزوالکتریک ثبت گردید. نتایج نشان داد که کمترین تردی در

2. Yoshioka

3. Multiple-point sheet sensor (MSS)

1. Turgor pressure

گردید. نتایج این تحقیق در توسعه سامانه‌های هوشمند درجه بندی میوه خیار بر اساس شاخص‌های کیفی کاربرد دارد.

## ۲- مواد و روش‌ها

جهت انجام این تحقیق، خیار گلخانه‌ای رقم ویولا از گلخانه‌های شهر ورامین در تیر ۱۳۹۳ به صورت تصادفی برداشت شد. نمونه‌ها تا حد امکان هم اندازه (طول، قطر و شکل همسان) انتخاب شدند. خیارهای برداشت شده دارای کیفیت ظاهری مناسب و بدون هرگونه لک و یا آسیب دیدگی بودند. جرم نمونه‌ها در محدوده ۹۳-۸۲ گرم، طول آن‌ها ۱۴۶-۱۳۹ میلی‌متر و قطر آن‌ها ۳۱-۲۸ میلی‌متر بود. نمونه‌ها درون جعبه‌های مقوایی به آزمایشگاه گروه مهندسی فنی کشاورزی پردیس ابوریحان دانشگاه تهران انتقال یافتند. بین نمونه‌های درون جعبه‌ها تکه کاغذهایی قرار داده شد. نصفی از نمونه‌ها در شرایط یخچال (دمای نگهداری  $2 \pm 5$  درجه سلسیوس و رطوبت نسبی  $3 \pm 70$  درصد) و نصف دیگر در شرایط آزمایشگاه (دمای  $3 \pm 25$  درجه سلسیوس و رطوبت نسبی  $3 \pm 35$  درصد) نگهداری شدند. قبل از هر آزمون مقادیر مشخص از نمونه‌های درون یخچال به مدت دو ساعت در شرایط آزمایشگاه قرار داده شدند. به منظور بررسی تغییرات بافت میوه خیار، آزمون‌ها در چهار بازه زمانی ۱، ۳، ۶ و ۹ روز پس از برداشت و در سه نقطه در طول خیار (نزدیک به سر، میانه و نزدیک به ته) انجام شدند. در هر مرحله، اندازه‌گیری شاخص‌های مکانیکی (سفتی و تردی) و آکوستیکی (فشار صدا) روی نمونه‌ها انجام گرفت.

### ۲-۱- آزمون پانچ برش عرضی

برای این آزمون از دستگاه کشش-فشار مواد بیولوژیک طراحی و ساخته شده توسط غایبی و همکاران [۳۱] استفاده شد (شکل ۱). از هر کدام از قسمت‌های سر، میانه و ته هر خیار یک برش عرضی به ضخامت ۱۵ میلی‌متر تهیه شد. آزمون پانچ با پرایی استوانه‌ای شکل به قطر ۳ میلی‌متر و سرعت بارگذاری ۲۵ میلی‌متر در دقیقه [۱۷، ۱۸] و در قسمت گوشت هر برش و با نفوذ پراب به اندازه ۱۰ میلی‌متر انجام شد.

قسمت تخمدان است، همچنین تردی در سر خیار بیشتر از ته آن است [۲۰].

با توجه به هزینه و زمان زیاد برای انجام آزمون‌ها، پیش‌بینی معیارها از روی عوامل تاثیر گذار بسیار مفید خواهد بود. با پیشرفت تکنولوژی استفاده از روش‌های هوشمند که دقت تخمین زیادی دارند جایگاه ویژه‌ای در علوم و مهندسی یافته‌اند. یکی از روش‌های هوشمند که الهام گرفته از سیستم عصبی بیولوژی مغز انسان است، شبکه عصبی مصنوعی می‌باشد. شبکه‌های عصبی مصنوعی به علت دقت مطلوب به همراه قدرت و سرعت بالا در شبیه‌سازی فرآیندهایی که درک و شناخت درستی از آن وجود نداشته و یا بررسی آن‌ها با روش‌های مرسوم بسیار دشوار و وقت‌گیر است، مقبولیت یافته و استفاده روزافزونی دارند [۲۱]. تحقیقاتی در مورد پیش‌بینی خصوصیات فیزیکی، مکانیکی و میزان رطوبت محصولات کشاورزی با استفاده از شبکه عصبی مصنوعی صورت گرفته است [۲۲، ۲۳]. برای پیش‌بینی محتوای رطوبت پسته [۲۴]، طبقه بندی پسته [۲۵] و برای جداسازی پسته‌های خندان از ناخندان از شبکه عصبی مصنوعی استفاده شده است [۷]. برای مدل سازی جرم بر اساس مشخصه‌های فیزیکی محصولاتی چون لیمو ترش [۲۶]، ماندارین [۲۷] و نارنگی [۲۸] از شبکه عصبی استفاده شده است. برای تشخیص تصاویر و گروه‌بندی محصول و علف‌های هرز [۲۹] و همچنین برای طبقه‌بندی سیب بر اساس کیفیت [۳۰] از شبکه عصبی استفاده شده است.

تا کنون پژوهشی در رابطه با پیش‌بینی ویژگی‌های کیفی میوه خیار با استفاده از شبکه عصبی گزارش نشده است. در این تحقیق آزمون مکانیکی و آزمون صوتی در شرایط و زمان‌های متفاوت نگهداری بر روی قسمت‌های مختلف میوه خیار انجام شده و شاخص تردی، سفتی و فشار صوت در تیمارهای مختلف به دست آمد. شبکه‌های عصبی مصنوعی MLP و RBF با الگوریتم‌های آموزش و ساختارهای مختلف برای پیش‌بینی شاخص تردی، سفتی و فشار صوت طراحی شدند. در نهایت با مقایسه و ارزیابی شبکه‌های عصبی مختلف بهترین مدل جهت پیش‌بینی شاخص تردی، سفتی و فشار صوت ارایه




Fig 1 The cross-cutting punch test

عنوان سفتی در نظر گرفته شد [۱۶].

## ۲-۲ آزمون آکوستیکی

سیستم آزمایشگاهی مورد استفاده شامل یک ضربه‌زن آونگی، حسگر صوتی (میکروفون)، رایانه دستی و نرم‌افزار Cool Edit Pro 2.1 جهت اندازه‌گیری و ضبط سیگنال‌های صدا بود. در این سیستم، میوه توسط یک آونگ ضربه‌زن شکسته و سیگنال صوتی ایجاد شده در اثر شکست بافت محصول به کمک صداسنج دریافت و در رایانه ثبت می‌شود (شکل ۲).

داده‌ها در کامپیوتر به صورت یک فایل متنی ذخیره شده و سپس نمودار نیرو-جابجایی برای هر یک از نمونه‌ها ترسیم گردید. شاخص تردی (CI) با استفاده از نیمه میانی نمودار نیرو-جابجایی (از عمق ۲/۵ تا ۷/۶ میلی‌متر) و رابطه (۱) محاسبه شد. [۵، ۱].

$D_{2t} = 2 \times F_t - (F_{t-1} + F_{t+1})$ , and  $CI = \sum |D_{2t}|$  که در این رابطه:  $D_{2t}$  مشتق دوم  $F$  در زمان  $t$ ،  $F_{t-1}$  و  $F_{t+1}$  مقدار نیرو در زمان‌های  $t-1$  و  $t+1$  و  $t$  شاخص تردی هستند. حداکثر مقدار نیرو در نمودار نیرو-جابجایی به

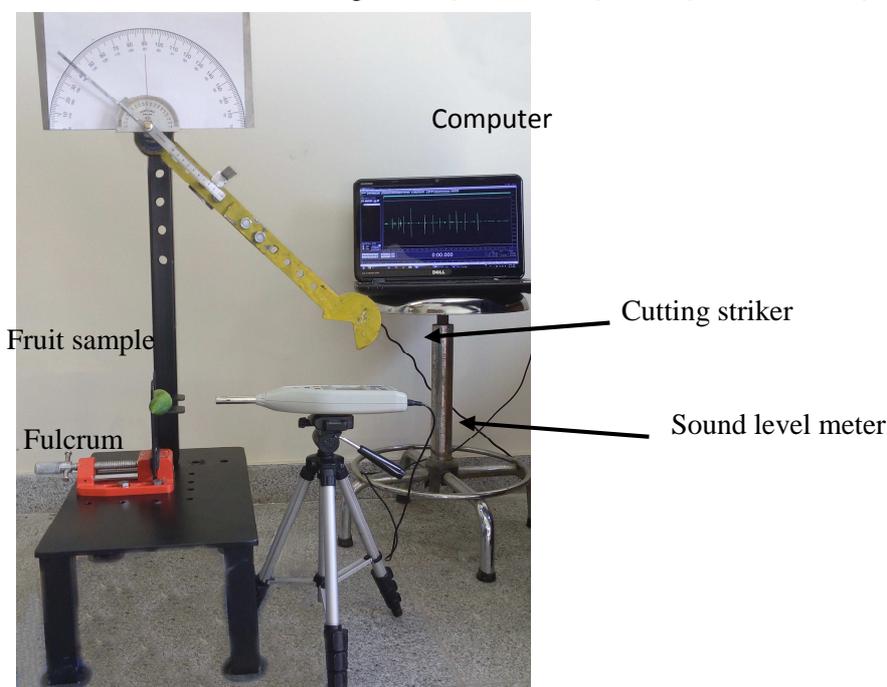


Fig 2 The acoustic test system used in this study

نرم‌افزار Cool Edit Pro 2.1 روی آن نصب شده فراهم گردد. رایانه دستی مورد استفاده در این تحقیق مدل DELL 5110 با سیستم عامل Windows 7 بود. با توجه به ماهیت ضربه‌ای آزمون، سرعت نمونه‌برداری ۱۹۲۰۰۰ هرتز در نظر گرفته شد. نمونه خیار شبیه به یک تیر یک سر گیردار درون

دستگاه صداسنج (مدل HT157 ساخت کشور ایتالیا) مورد استفاده در این تحقیق از نوع کلاس یک برای اندازه‌گیری دقیق صدا بود. خروجی ولتاژ متناوب دستگاه صداسنج توسط یک کابل رابط به ورودی کارت صدای رایانه متصل گردید تا امکان ذخیره‌سازی سیگنال صدا در حوزه زمان توسط رایانه‌ای که

شبکه از الگوریتم یادگیری پس انتشار<sup>۲</sup> خطا استفاده می‌شود. ساختار شبکه RBF شبیه MLP است و معمولاً دارای یک لایه پنهان می‌باشد؛ ولی محاسبات این شبکه به وسیله نرون‌هایی متفاوت در لایه پنهان انجام می‌شود. در این تحقیق نیز برای طراحی شبکه‌های عصبی مصنوعی از شبکه عصبی چند لایه پرسپترون و شبکه عصبی با تابع پایه شعاعی و الگوریتم‌های آموزش مومنتوم، گرادیان نزولی و لونیگ-مارکواریت و توابع آستانه SigmoidAxon و TanhAxon استفاده شد.

شبکه‌های عصبی با استفاده از سه نرون در لایه ورودی شامل داده‌های مدت زمان ماندگاری، شرایط نگهداری و موقعیت اعمال ضربه و سه نرون در لایه خروجی شامل فشار صدا، شاخص تردی و سفتی طراحی شد (شکل ۴). ابتدا به‌طور تصادفی داده‌های موجود به دو دسته مجموعه آموزش با ۸۴ عضو (۷۰ درصد کل داده‌ها)، اعتبار سنجی با ۲۴ عضو (۲۰ درصد کل داده‌ها) و مجموعه آزمون با ۱۲ عضو (۱۰ درصد کل داده‌ها) تقسیم‌بندی شدند. جهت دستیابی به شبکه‌هایی همگرا و با عملکرد مطلوب قبل از به کارگیری داده‌ها برای آموزش و آزمون شبکه‌ها، داده‌ها نرمالیزه شدند. از رابطه ۲ برای نرمالیزاسیون داده‌ها استفاده شد [۳۳].

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

X: داده خام اولیه،  $x_n$  داده نرمالیزه شده،  $x_{min}$  و  $x_{max}$  به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه می‌باشد.

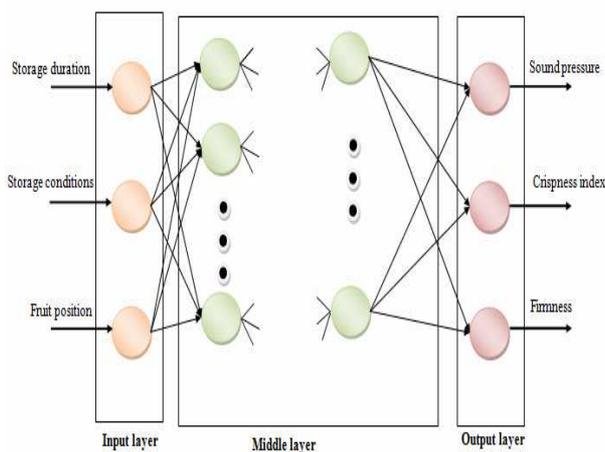


Fig 4 Artificial neural network topology

گیره دستگاه قرار داده شد و در هر بار ضربه یک تکه از آن به ضخامت ۱۰ میلی‌متر توسط ضربه برشی آونگ، بریده می‌شد. آونگ برشی دارای دهانه V شکل با زاویه تیزی ۶۰ درجه بود. محل چرخش آونگ روانکاری شد تا صدای مزاحم ایجاد نشود. ابتدا آونگ بالا آورده شده و در زاویه ۶۰ درجه نگه داشته می‌شد. سپس نمونه خیار در گیره دستگاه قرار داده می‌شد و در پایان آونگ رها می‌گردید تا با نیروی حاصل از حرکت آونگ نمونه بشکند. شکل ۳ یک نمونه سیگنال حوزه زمان ذخیره شده هنگام برش میوه خیار را نمایش می‌دهد.

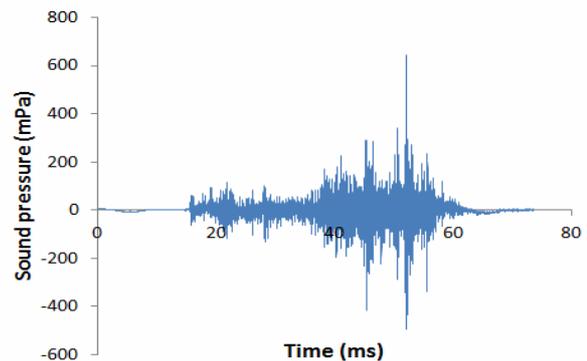


Fig 3 A sample of the recorded signal in the time domain during cutting fruit

سیگنال‌های صدای ذخیره شده با استفاده از نرم افزار Matlab فراخوانی شده و بر مبنای تبدیل فوریه سریع به حوزه فرکانس تبدیل و در قالب فایل اکسل در حافظه رایانه ذخیره شدند. در این تحقیق میکروفون صداسنج با فاصله ۷۶ میلی‌متر از سطح میوه و در راستای ضربه زن نصب شد. آزمون در یک اتاق با پنجره دارای شیشه دو جداره انجام شد به طوری که صدای محیط کمتر از ۳۰ دسی بل بود و حداقل نویز را در سیگنال‌های صوتی ایجاد می‌کرد. بررسی سیگنال‌های حوزه فرکانس نشان داد که فرکانس ۴۶/۸ هرتز فرکانس غالب میوه خیار رقم ویولا می‌باشد؛ لذا میزان فشار صوت بر حسب میلی-پاسکال در این فرکانس در نظر گرفته شد.

## ۲-۳- شبکه عصبی مصنوعی

شبکه عصبی پرسپترون چند لایه (MLP) و شبکه عصبی با تابع پایه شعاعی (RBF) با الگوریتم‌های آموزش و همچنین توابع آستانه مختلف از شبکه‌های عصبی مصنوعی رایج مورد استفاده در علوم و مهندسی می‌باشند [۳۲]. شبکه عصبی چند لایه پرسپترون یک شبکه پیش‌خور<sup>۱</sup> با یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. برای آموزش این

### ۳- نتایج و بحث

منتخبی از بهترین نتایج حاصل از استفاده از شبکه‌های عصبی پرسپترون چند لایه (MLP) و تابع پایه شعاعی (RBF) همراه با توابع آستانه TanhAxon و SigmoidAxon با توابع آموزش مومنتم، گرادیان نزولی و لونیبرگ-مارکووارت برای پیکربندی‌های مختلف جهت پیش‌بینی همزمان مقادیر شاخص تردی، سفتی و فشار صدای میوه خیار رقم ویولا به ترتیب در جداول ۱ و ۲ آمده است.

بررسی نتایج حاصل شده در خصوص شبکه عصبی پرسپترون چند لایه همراه با تابع آستانه SigmoidAxon و تابع آموزش گرادیان نزولی نشان داد در بین این نوع شبکه‌های عصبی شبکه‌ای با پیکربندی ۳-۵-۳، یعنی شبکه‌ای با ۳ ورودی، یک لایه پنهان با ۵ گره و ۳ خروجی، بهترین نتیجه را برای پیش‌بینی همزمان خواص مکانیکی و صوتی خیار دارا بود و فشار صوت، شاخص تردی و سفتی را به ترتیب با ضرایب تبیین ۰/۹۹۸۶، ۰/۹۴۱۹ و ۰/۸۹۳۳ و ریشه میانگین مربعات خطای ۰/۰۱۶، ۰/۰۵۳ و ۰/۰۶۷ تخمین زد. نتایج شبکه عصبی پرسپترون چند لایه همراه با تابع آستانه SigmoidAxon و تابع آموزش لونیبرگ-مارکووارت نشان داد که در این نوع، شبکه با پیکربندی ۳-۴-۳ بهترین نتیجه را در پیش‌بینی خواص مکانیکی و صوتی خیار داشت. به طوری که این شبکه توانست فشار صوت، شاخص تردی و سفتی را به ترتیب با ضرایب تبیین ۰/۹۹۶۳، ۰/۹۵۲۲ و ۰/۸۶۱۸ و ریشه میانگین مربعات خطای ۰/۰۱۸، ۰/۰۴۸ و ۰/۰۷۳ تخمین بزند. در نهایت همین شبکه با تابع آموزش مومنتم در مناسب‌ترین عملکرد با پیکربندی ۳-۷-۳ خواص مکانیکی و صوتی میوه خیار را با ضرایب تبیین ۰/۹۸۷۰، ۰/۹۱۰۹ و ۰/۸۲۲۳ و ریشه میانگین مربعات خطای ۰/۰۳۸، ۰/۰۶۵ و ۰/۰۸۰ تخمین زد. مقایسه بین شبکه‌های چند لایه پرسپترون با تابع آستانه SigmoidAxon و قواعد آموزش مختلف نشان داد که شبکه عصبی با تابع آموزش گرادیان نزولی با پیکربندی ۳-۵-۳، سه پارامتر سفتی، تردی و فشار صدای میوه خیار رقم ویولا را به طور هم‌زمان با بهترین دقت پیش‌بینی می‌کند.

برای ارزیابی شبکه‌ها از دو معیار ضریب تبیین ( $R^2$ ) و ریشه میانگین مربعات خطا (RMSE) استفاده گردید. ضریب تبیین میزان همبستگی بین داده‌های خروجی شبکه عصبی و داده‌های مشاهده شده را تعیین می‌کند و از رابطه ۳ محاسبه می‌شود. مقدار ایده آل آن برابر یک می‌باشد. میانگین مربعات خطا، اختلاف داده‌های پیش‌بینی شده از داده‌های واقعی را تعیین می‌کند و ریشه آن از رابطه ۴ محاسبه می‌شود. هدف یک شبکه عصبی مطلوب آن است که میزان این خطا به کمترین مقدار ممکن برسد و مقدار ایده آل آن برابر صفر می‌باشد [۳۳].

$$R^2 = 1 - \frac{\sum_{k=1}^n [S_k - T_k]}{\sum_{k=1}^n [S_k - T_m]} \left( T_m = \frac{\sum_{k=1}^n S_k}{n} \right)$$

در این رابطه‌ها،  $S_k$  مقدار پیش‌بینی شده به وسیله شبکه عصبی مصنوعی برای الگوی  $k$ ام،  $T_k$  مقدار هدف (آزمایشی) برای الگوی  $k$ ام،  $T_m$  میانگین مقادیر پیش‌بینی شده و  $n$  تعداد الگوهای آموزشی است.

$$RMSE = \sqrt{\frac{\sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2}{n_p \times n_o}}$$

که در آن، RMSE ریشه میانگین مربعات خطا،  $S_{ip}$  خروجی شبکه در نرون  $i$ ام و الگوی  $p$ ام،  $T_{ip}$  خروجی هدف در نرون  $i$ ام و الگوی  $p$ ام،  $n_p$  تعداد الگوها،  $n_o$  تعداد نرون‌های لایه خروجی،  $N$  تعداد نرون‌های خروجی و  $M$  تعداد الگوهای آموزشی است.

شاخص تردی، سفتی و فشار صوت توسط شبکه‌های عصبی مصنوعی MLP و RBF با الگوریتم‌های آموزش و توابع آستانه مذکور با یک و دو لایه مخفی و با نرون‌های متفاوت آموزش و آزمایش شدند و بهترین شبکه‌ها انتخاب شدند. معیار انتخاب، شبکه‌ای است که بهترین آموزش را دیده باشد و بهترین پیش‌بینی نتایج را ارائه دهد در واقع کمترین ریشه میانگین مربعات خطا به همراه بیشترین ضریب تبیین را داشته باشد.

۰/۸۶۱۷ و ریشه میانگین مربعات خطای ۰/۰۱۹، ۰/۰۵۷ و ۰/۰۷۲ پیش‌بینی نمود. برای شبکه RBF با تابع آستانه SigmoidAxon و تابع آموزش لونیبرگ-ماکواریت نیز پیکربندی ۳-۳-۳ با ضرایب تبیین ۰/۹۹۹۳، ۰/۹۵۵۳ و ۰/۸۳۷۶ و ریشه میانگین مربعات خطای ۰/۰۰۸، ۰/۰۴۶ و ۰/۰۸۴ دارای بهترین عملکرد بود. شبکه RBF با این تابع آستانه و تابع آموزش مومتم دارای عملکرد مناسبی جهت پیش‌بینی مقادیر نبود. شبکه عصبی RBF با تابع آستانه TanhAxon با تابع آموزش گرادیان نزولی پیکربندی ۳-۴-۳ دارای بهترین عملکرد بوده و فشار صدا، شاخص تردی و سفتی را با ضرایب تبیین ۰/۹۹۶۱، ۰/۹۴۸۷ و ۰/۸۶۷۰ و ریشه میانگین مربعات خطای ۰/۰۲۰، ۰/۰۴۹ و ۰/۰۷۳ پیش‌بینی نمود. شبکه عصبی تابع پایه شعاعی برای تابع آستانه TanhAxon و تابع آموزش لونیبرگ-ماکواریت با پیکربندی ۳-۳-۳ با ضرایب تبیین ۰/۹۹۹۶، ۰/۹۴۴۵ و ۰/۸۴۱۶ و ریشه میانگین مربعات خطای ۰/۰۰۶، ۰/۰۵۴ و ۰/۰۸۰ بالاترین قدرت پیش‌بینی خواص را دارا بود. این شبکه با تابع آموزش مومتم نیز با پیکربندی ۳-۳-۳ دارای مطلوب‌ترین عملکرد با ضرایب تبیین ۰/۹۹۵۸، ۰/۹۳۲۸ و ۰/۸۵۱۴ و ریشه میانگین مربعات خطای ۰/۰۲۸، ۰/۰۵۸ و ۰/۰۷۷ بود. با مقایسه شبکه‌های عصبی با توابع آموزش مختلف این نتیجه حاصل شد که تابع گرادیان نزولی دارای بهترین قدرت پیش‌بینی می‌باشد. به طور کلی در بین پیکربندی‌های شبکه‌ی تابع پایه شعاعی، پیکربندی ۳-۴-۳ با تابع آستانه TanhAxon و تابع آموزش گرادیان نزولی دارای بهترین عملکرد بود.

در مقایسه بین انواع شبکه‌های MLP و RBF با توابع آستانه، توابع آموزش و پیکربندی‌های مختلف این نتیجه مشخص شد که شبکه عصبی پرسپترون چند لایه با تابع آستانه TanhAxon و تابع آموزش مومتم و پیکربندی ۳-۵-۳-۳ مناسب‌ترین عملکرد در پیش‌بینی مقادیر آزمون را داراست و فشار صوت، شاخص تردی و سفتی را با ضرایب تبیین ۰/۹۹۷۳، ۰/۹۴۵۶ و ۰/۹۱۲۹ و ریشه میانگین مربعات خطای ۰/۰۲۱، ۰/۰۵۲ و ۰/۰۵۹ تخمین زد.

نتایج نشان داد که شبکه عصبی پرسپترون چند لایه همراه با تابع آستانه TanhAxon و تابع آموزش گرادیان نزولی با پیکربندی ۳-۵-۳ (شبکه‌ای با ۳ ورودی، دو لایه پنهان، لایه اول با ۶ گره و لایه دوم با ۵ گره، و ۳ خروجی) بهترین عملکرد را برای پیش‌بینی مقادیر آزمون دارا بود به طوری که فشار صوت، شاخص تردی و سفتی را به ترتیب با ضرایب تبیین ۰/۹۹۶۳، ۰/۹۵۹۲ و ۰/۸۸۶۷ و ریشه میانگین مربعات خطای ۰/۰۱۷، ۰/۰۴۵ و ۰/۰۶۹ تخمین زد. نتایج همین شبکه با تابع آموزش لونیبرگ-ماکواریت نشان داد که شبکه با پیکربندی ۳-۷-۳ بهترین نتیجه را در پیش‌بینی خواص مکانیکی و صوتی خیار را داشت و توانست فشار صوت، شاخص تردی و سفتی را به ترتیب با ضرایب تبیین ۰/۹۹۷۹، ۰/۹۵۳۷ و ۰/۸۳۲۹ و ریشه میانگین مربعات خطای ۰/۰۱۴، ۰/۰۴۸ و ۰/۰۸۲ تخمین بزند. در نهایت این شبکه با تابع آموزش مومتم توانست با پیکربندی ۳-۵-۳-۳ خواص مکانیکی و صوتی میوه خیار را با ضرایب تبیین ۰/۹۹۷۳، ۰/۹۴۵۶ و ۰/۹۱۲۹ و ریشه میانگین مربعات خطای ۰/۰۲۱، ۰/۰۵۲ و ۰/۰۵۹ تخمین زد. مقایسه بین شبکه‌های چند لایه پرسپترون با تابع آستانه TanhAxon و توابع آموزش مختلف نشان داد که شبکه عصبی که شبکه با تابع آموزش مومتم با پیکربندی ۳-۵-۳-۳ از بهترین عملکرد جهت پیش‌بینی خواص خیار برخوردار است. همچنین بررسی نتایج نشان داد که این شبکه دقت بالاتری در تخمین مقادیر آزمون را نسبت به شبکه‌های عصبی پرسپترون چند لایه با تابع آستانه SigmoidAxon دارد، در نتیجه بهترین شبکه پرسپترون چند لایه می‌باشد.

نتایج مدل شبکه‌ی تابع پایه شعاعی (RBF) همراه با توابع آستانه SigmoidAxon و TanhAxon با توابع آموزش مومتم، گرادیان نزولی و لونیبرگ-ماکواریت در جدول ۲ نمایش داده شده است. همان‌طور که ملاحظه می‌شود برای تابع آستانه SigmoidAxon و تابع آموزش گرادیان نزولی پیکربندی ۳-۳-۳ دارای بهترین عملکرد بوده و فشار صدا، شاخص تردی و سفتی را با ضرایب تبیین ۰/۹۹۵۷، ۰/۹۳۲۱ و

**Table 1** Some of the best MLP neural network topologies to predict test values

Firm		CI		SP		The number of neurons in the second hidden layer	The number of neurons in the first hidden layer	Training function	Threshold function
R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE				
0.8933	0.067	0.9419	0.053	0.9986	0.016	0	5	Levenberg Marquardt	SigmoidAxon
0.8627	0.075	0.9519	0.049	0.9983	0.011	0	6		
0.8351	0.084	0.9524	0.056	0.9963	0.023	2	5		
0.7812	0.091	0.9519	0.052	0.9796	0.050	1	6		
0.8618	0.073	0.9522	0.048	0.9963	0.018	0	4		
0.8192	0.086	0.9586	0.050	0.9939	0.022	2	4		
0.8066	0.088	0.9588	0.050	0.9976	0.016	2	5		
0.8209	0.085	0.9562	0.047	0.9995	0.007	5	6		
0.7644	0.102	0.9177	0.063	0.9882	0.037	0	5		
0.7971	0.088	0.9119	0.065	0.9890	0.041	0	6		
0.8223	0.080	0.9109	0.065	0.9870	0.038	0	7		
0.7563	0.182	0.8701	0.208	0.9101	0.255	4	3		
0.7380	0.181	0.8281	0.209	0.9350	0.261	3	4		
0.8513	0.077	0.9441	0.052	0.9982	0.014	0	4	Levenberg Marquardt	tanhAxon
0.8592	0.078	0.9251	0.060	0.9993	0.009	0	7		
0.8014	0.088	0.9503	0.052	0.9991	0.011	0	8		
0.8737	0.071	0.9578	0.045	0.9972	0.015	5	3		
0.8433	0.081	0.9633	0.047	0.9933	0.023	3	4		
0.8867	0.069	0.9592	0.045	0.9963	0.017	5	6		
0.8284	0.084	0.9598	0.046	0.9957	0.019	4	7		
0.8278	0.083	0.9299	0.058	0.9948	0.020	0	5		
0.8329	0.082	0.9537	0.048	0.9979	0.014	0	7		
0.7859	0.092	0.9630	0.048	0.9972	0.021	2	7		
0.8193	0.086	0.9515	0.052	0.9997	0.007	3	7		
0.8305	0.084	0.9553	0.046	0.9979	0.015	0	7		
0.9057	0.065	0.9448	0.052	0.9916	0.026	6	3		
0.9036	0.064	0.9454	0.051	0.9924	0.024	4	4		
0.9077	0.063	0.9401	0.055	0.9941	0.022	7	4		
0.9129	0.059	0.9456	0.052	0.9973	0.021	3	5		

SP: sound pressure, CI: crisness index, Firm: firmness.

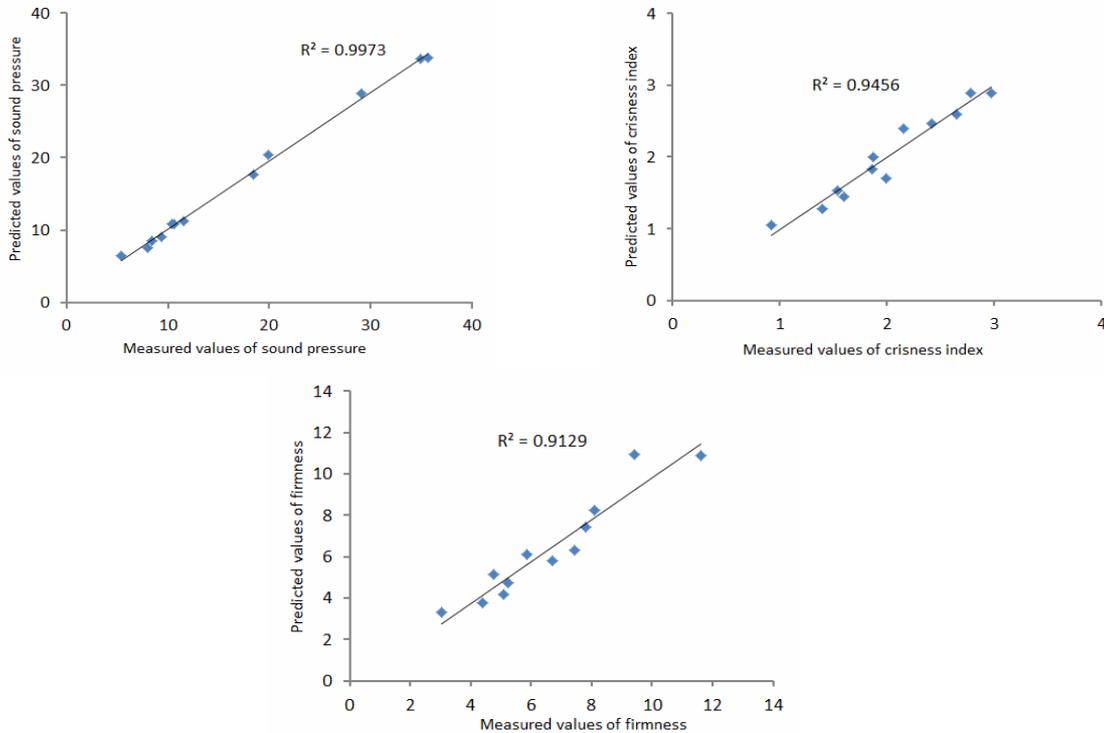
**Table 2** Some of the best RBF neural network topologies to predict test values

Firm		CI		SP		The number of neurons in the hidden layer	Training function	Threshold function
R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE			
0.8617	0.072	0.9321	0.057	0.9957	0.019	3	Levenberg Marquardt	SigmoidAxon
0.6966	0.108	0.9103	0.067	0.9746	0.049	8		
0.8376	0.084	0.9553	0.046	0.9993	0.008	3		
0.8352	0.082	0.9407	0.054	0.9996	0.005	4		
0.8465	0.081	0.9389	0.055	0.9997	0.005	9		
0.4737	0.180	0.7848	0.213	0.5161	0.272	3		
0.1105	0.182	0.3313	0.216	0.2500	0.281	6		
0.3903	0.182	0.3380	0.215	0.8679	0.271	8		
0.8554	0.075	0.9237	0.061	0.9988	0.010	3	Levenberg Marquardt	tanhAxon
0.8670	0.073	0.9487	0.049	0.9961	0.020	4		
0.8429	0.082	0.9410	0.053	0.9950	0.021	5		
0.8068	0.085	0.9352	0.056	0.9942	0.021	8		
0.8416	0.080	0.9445	0.054	0.9996	0.006	3		
0.8246	0.086	0.9473	0.051	0.9992	0.009	5		
0.8222	0.084	0.9510	0.050	0.9997	0.005	6		
0.8514	0.077	0.9328	0.058	0.9958	0.028	3	Momentum	
0.8445	0.080	0.9319	0.059	0.9982	0.024	4		
0.7954	0.085	0.9081	0.066	0.9865	0.035	8		
0.8131	0.085	0.9267	0.060	0.9949	0.027	10		

SP: sound pressure, CI: crisness index, Firm: firmness.

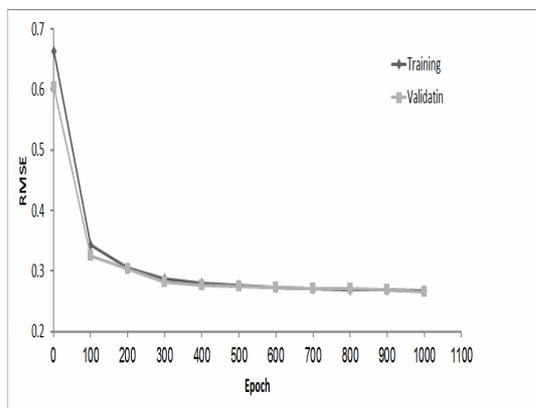
دقیق میزان فشار صوت، شاخص تردی و سفتی می‌باشد. به نحوی که می‌توان از این شبکه عصبی مصنوعی در طراحی سامانه‌های هوشمند تشخیص کیفیت خیار بر حسب زمان و شرایط نگهداری استفاده کرد.

مقایسه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده توسط شبکه عصبی برای بهترین مدل در شکل ۵ نشان داده شده است. همان‌طور که مشاهده می‌شود پراکندگی داده‌ها نزدیک خط نیمساز ربع اول (خط با زاویه  $45^\circ$ ) بسیار زیاد است که این خود دلیلی بر توانایی شبکه عصبی مصنوعی در تخمین



**Fig 5** Dispersion curve for the measured and the predicted values of sound pressure (mPa), crispness index and firmness (N) by MLP neural network with TanhAxon threshold function, momentum training function and 3-5-3-3 topology.

محدوده  $\pm 1/96$  میلی پاسکال می‌باشد. برای شاخص تردی و سفتی مقادیر تفاوت به ترتیب در محدوده  $\pm 0/29$  و  $\pm 1/50$  نیوتن می‌باشد که بیانگر دقت شبکه در تخمین مقادیر مذکور است.



**Fig 6** The changing of RMSE for training and validation for the optimized network versus the number of epoch

شکل ۶ مقادیر ریشه میانگین مربعات خطا در فرآیند آموزش و اعتبارسنجی را بر حسب تعداد چرخه آموزش نشان می‌دهد. همان‌گونه که مشاهده می‌شود با افزایش تعداد چرخه، خطای آموزش و اعتبارسنجی شبکه کاهش می‌یابد بدین معنی که دقت تخمین شبکه افزایش می‌یابد. لازم به ذکر است که افزایش تعداد چرخه، زمان یادگیری شبکه را افزایش می‌دهد. بنابراین تعداد چرخه ۵۰۰ را می‌توان به عنوان تعداد چرخه مطلوب با عملکرد مناسب معرفی نمود؛ زیرا در این چرخه شبکه دارای قدرت یادگیری مناسب در زمان معقول می‌باشد و با افزایش بیشتر تعداد چرخه RMSE تغییر محسوسی نمی‌کند.

مقادیر اندازه‌گیری شده داده‌های آزمایش و مقادیر پیش‌بینی شده توسط بهترین شبکه عصبی مصنوعی آموزش داده شده، همچنین تفاوت بین مقادیر واقعی و مقادیر پیش‌بینی شده در جدول ۳ آورده شده است. همان‌گونه که مشاهده می‌شود تفاوت بین مقادیر واقعی و پیش‌بینی شده فشار صدا در

**Table 3** Test data values (measured and predicted by the network (MLP with TanhAxon threshold function and education function of momentum and topology 3-5-3-3) and the difference between them)

Firm (N)			CI			SP (mPa)		
Experiental value	predicted value	Real error	Experiental value	predicted value	Real error	Experiental value	predicted value	Real error
3.04	3.31	-0.26	0.92	1.05	-0.13	5.41	6.40	-0.99
8.10	8.26	-0.16	2.65	2.59	0.06	19.91	20.36	-0.45
6.72	5.81	0.91	1.87	2.01	-0.14	10.60	10.84	-0.24
5.08	4.19	0.88	1.40	1.28	0.12	8.41	8.48	-0.07
9.42	10.92	-1.50	2.78	2.90	-0.12	35.03	33.74	1.29
11.60	10.89	0.71	2.98	2.89	0.09	35.71	33.75	1.96
5.22	4.75	0.47	1.54	1.52	0.02	10.46	10.80	-0.34
5.85	6.10	-0.25	2.41	2.46	-0.05	29.09	28.86	0.23
4.76	5.14	-0.38	1.86	1.83	0.03	9.34	9.11	0.23
7.80	7.43	0.37	2.16	2.40	-0.24	18.47	17.62	0.85
4.41	3.78	0.63	1.60	1.45	0.15	7.96	7.56	0.40
7.46	6.30	1.16	1.99	1.70	0.29	11.55	11.23	0.32

SP: sound pressure, CI: crissness index, Firm: firmness.

شاخص تردی و سفتی بر حسب زمان و شرایط نگهداری مورد استفاده قرار گیرد.

### ۳- نتیجه گیری

- شبکه‌های عصبی مصنوعی MLP و RBF به طور موفقیت آمیزی ارتباط بین متغیرهای مستقل (زمان ماندگاری، شرایط ماندگاری و موقعیت انجام آزمون روی محصول) و متغیرهای وابسته (فشار صدا، شاخص تردی و سفتی) را یاد گرفت.

- در بین شبکه‌های عصبی پرسپترون چندلایه، شبکه با تابع آستانه TanhAxon و تابع آموزش مومنتوم با پیکربندی ۳-۵-۳ بهترین عملکرد در پیش‌بینی مقادیر آزمون را دارا بود. این شبکه مقادیر فشار صوت، تردی و سفتی خیار را با ضرایب تبیین ۰/۹۹۷۳، ۰/۹۴۵۶ و ۰/۹۱۲۹ و ریشه میانگین مربعات خطای ۰/۰۲۱، ۰/۰۵۲ و ۰/۰۵۹ تخمین زد.

- در بین شبکه‌ها با تابع پایه شعاعی، شبکه با پیکربندی ۳-۴-۳، تابع آستانه TanhAxon و تابع آموزش گرادیان نزولی دارای بهترین عملکرد بود. این شبکه مقادیر فشار صدا، شاخص تردی و سفتی را با ضرایب تبیین ۰/۹۹۶۱، ۰/۹۴۸۷ و ۰/۸۶۷۰ و ریشه میانگین مربعات خطای ۰/۰۲۰، ۰/۰۴۹ و ۰/۰۷۳ پیش‌بینی نمود.

- در نهایت شبکه عصبی پرسپترون چندلایه با تابع آستانه TanhAxon و تابع آموزش مومنتوم با پیکربندی ۳-۵-۳ به عنوان مناسب‌ترین شبکه جهت پیش‌بینی فشار صوت، تردی و سفتی خیار رقم ویولا تشخیص داده شد.  
- نتایج این تحقیق می‌تواند در توسعه یک سامانه هوشمند برای تعیین شاخص‌های کیفی خیار از قبیل صدای شکست،

### ۴- تشکر و قدردانی

از معاونت محترم پژوهشی پردیس ابوریحان دانشگاه تهران به جهت مساعدت و تامین هزینه‌های این پژوهش قدردانی می‌گردد.

### ۵- منابع

- [1] Horire, H., Ito, H., Ippoushi, K., Azuma, K. and Igarashi, I. 2004. Evaluation of the physical quality of mesocarp of cucumber fruit. Hort. Res. (Japan), 3: 425-428.
- [2] Fatemi, H. 1380. Food chemistry. Sahami Enteshar press. 180pp.
- [3] Meydani, J. and Hashemi, A. 1376. Postharvest physiology. Nashre Keshavarzi pres. 201 pp.
- [4] Deman, J.M. 1384. Principles of Food chemistry. Ghanbarzadeh, B. Aeizh pres. 217-224.
- [5] Yoshioka, Y., Horie, H., Sugiyama, M. and Sakata, Y. 2009. Quantifying cucumber fruit crispness by mechanical measurement. J. Breed. Sci: 59: 139-147.
- [6] Brennan, J. G. 1984. Sensory analysis of foods (J. R. Piggott). Elsevier Applied Science.
- [7] Mahmoudi, A. 1385. Development of a suitable algorithm using artificial neural network for sorting of pistachio nuts with

- from fundamentals to advanced theory. John Wiley & Sons, Inc., Hoboken, New Jersey.
- [22] Mokhtarian, M., Tavakolipor, H. and Koshki, F. 1390. Prediction of pistachio physical properties during process using artificial neural networks. *J. Food science and technology*, 3(3): 25-38.
- [23] Tavakoli Hashtjin, T., Khosh Taghaza, M.H. and Gorjian, Sh. 1393. Modeling of thin-layer drying kinetics of barberry Fruit (*Berberis Vulgaris*) using artificial neural network. *J. food science and technology*, 45(11): 1-12.
- [24] Baharlooei, A., Omid, M. and Rafiee, Sh. 1386. Prediction of Akbari variety of pistachio using artificial neural networks. *J. Food science and technology*, 3(3): 45-56.
- [25] Ghazanfari, A., Irudayaraj, J. and Kusalik, A. 1996. Grading pistachio nuts using a neural networks approach. *Journal of Trans. ASAE*, 39, 2319– 2324.
- [26] Miraei-Ashtiani, S.H., Baradaran-Motie, J., Emadi, B. and Aghkhani, M.H. 2014. Models for predicting the mass of lime fruits by some engineering properties. *Journal of Food Science and Technology*, 51(11): 3411-3417.
- [27] Khadivi-Khub, A. 2013. Analysis of some technological and physical characters of mandarin (*Citrus reticulata*) fruit in Iran. *ISRN Agronomy*, vol. 2013, 4 pages.
- [28] Rashidi, M. and Keshavarzpour, F. 2011. Prediction of tangerine mass based on geometrical properties. *Academic Journal of Plant Sciences*, 4 (4): 98-104.
- [29] Yang, C.C., Prashier, S.O., Landry, J.A., Ramaswamy, H.S. and Ditommaso, A. 2000. Application of neural networks in image recognition and classification of crop and weeds. *Canadian Agricultural Engineering*, 42 (3): 147-152.
- [30] Kavdir, I., and Guyer, D.E. 2002. Apple sorting using artificial neural network and spectral imaging. *Trans. ASAE*, 45(6): 1995-2005.
- [31] Ghaebi, S.M., S.R. Hassan-Beygi, and M.H. Kianmehr. 2008. Biological material test device: Iranian Patent Number 54999, Tehran, Iran.
- [32] Jam, L. and Fanelli, A.M. 2000. Recent advances in artificial neural networks design and applications, CRC Press, 2000.
- [33] Zarifneshat, S., Rohani, A., Ettefagh, M.M. and Saeidirad, M.H. 1391. Predictions of apple bruise volume by using RBF artificial neural network and comparison it with regression. *J. food processing and preservation*, 4 (2): 45-65.
- closed shells using impact acoustics. University of Tehran. Thesis of Ph.D.
- [8] Khoshnam, F. 1391. Acoustic Response Analysis of Melon by Fourier and Wavelet Transforms For Detection of Ripeness. University of Tehran. Thesis of Ph.D.
- [9] De Belie, N., Schotte, S., Lammertyn, J., Nicolai, B. and De Baerdemaeker, J. 2000. Firmness changes of pear fruit before and after harvest with the acoustic impulse response technique. *J. Agr. Eng. Res*, 77: 183-191.
- [10] Harker, F.R., Redgwell, R.J., Hallett, I.C., Murray, S. and Carter, G. 1997. Texture of fresh fruit. *Hort. Rev*, 20: 212–224.
- [11] Aboonajmi, M. Jahangiri, M. and Hassan-beygi, S.R. 2015. A review on application of acoustic analysis on quality evaluation of agro-food products. *J. Food Processing and Preservation*. doi: 10.1111/jfpp.12444.
- [12] Wang, J., Gomez, A. H. and Pereira, A.G. 2006. Acoustic impulse response for measuring the firmness of mandarin during storage. *J. Food Quality*, 29: 392–404.
- [13] Anonymos. 1393. Agricultural products statistics 1391-92. Iran Agricultural ministry.
- [14] Breene, W.M., Davis, D.W. and Chou, H. 1972. Texture profile analysis of cucumbers. *J. Food Sci*, 37: 113–117.
- [15] Sakata, Y., Horie, H., Ohara, T., Kawasaki, Y. and Sugiyama, M. 2008. Influences of rootstock cultivar and storage on the texture of cucumber fruits. *J. Japan. Soc. Hortic. Sci*, 77: 47–53.
- [16] Haruka, D., Kazutake, O. and Kaoru, K. 2006. Mechanical stress distributions in cross-sections of cucumber cultivars during the fracture process. *J Sci Food Agric*, 86: 26–34.
- [17] Aliabadi, E. 1388. Evaluating the traits related with fruit flavor and their heritability in cucumber. University of Tehran. Thesis of Master of Science.
- [18] Ravanbakhsh, M. 1390. Investigation of fruit quality variation in fresh cucumber. University of Tehran. Thesis of Master of Science.
- [19] Thompson, R.L., Fleming, H.P., Hamann, D.D. and Monroe, R.J. 1982. Method for determination of firmness in cucumber slices. *J. Texture Studi*, 13: 311-324.
- [20] Sakurai, N., Iwatani, S., Terasaki, S. and Yamamoto, R. 2005. Texture evaluation of cucumber by a new acoustic vibration method. *J. Japan. Soc. Hortic. Sci*, 74: 31–35.
- [21] Gupta, M.M., Jin, J. and Homma, N. 2003. Static and dynamic neural networks:

## Prediction of Cucumber Acoustic Response, Crispness Index and Firmness Using Artificial Neural Networks

Jahangiri-Saleh, M. <sup>1</sup>, Hassan-Beygi, S. R. <sup>2\*</sup>, Aboonajmi, M. <sup>2</sup>, Lotfi, M. <sup>4</sup>

1. Ph.D Student, Department of Agro-technology, College of Abouraihan, University of Tehran, Tehran, Iran.

2. Associate Prof, Department of Agro-technology, College of Abouraihan, University of Tehran, Tehran, Iran.

3. Associate Prof, Department of Agro-technology, College of Abouraihan, University of Tehran, Tehran, Iran.

4. Associate Prof, Department of Horticultural Science, College of Abouraihan, University of Tehran, Tehran, Iran.

(Received: 2015/11/02 Accepted: 2015/12/05)

Cucumber fruit consumes in high quantities during all seasons in Iran; so it is important to evaluate parameters that affected the cucumber quality. Measurement of these parameters is expensive and time-consuming process. Therefore, parameters prediction due to affecting factors will be more useful. In this research work, artificial neural networks used for modelling the relationship between mechanical properties (crispness index and firmness) and sound pressure during cutting (acoustic response) with storage time, storage conditions on different positions on cucumber fruit. The networks input were storage time, storage conditions and test position on the fruit length. The networks output targets were the values of the mechanical properties and acoustic response. The different networks defined and trianed with different topologies. Multi layer perception (MLP) and radial basis function (RBF) networks used with different number of neurons. The training rules were Momentum, Conjugate Gradient and Levenberg-Marquardt. The transfer functions were TanhAxon and SigmoidAxon. The networks evaluated respected to estimation the accuracy of acoustic and mechanical properties. The results showed that MLP network with Momentum training function, TanhAxon transfer function and 3-5-3-3 topology had the best accuracy for prediction of acoustic and mechanical properties of Viola cucumber fruit. This network can predict the sound pressure, crispness index and firmness of the fruit with determinations coefficient of 0.9973, 0.9456 and 0.9129 and root mean square error of 0.021, 0.052 and 0.059 respectively.

**Keywords:** Artificial Neural Networks, Cucumber, Crispness Index, Firmness, Sound pressure, Viola

---

\* Corresponding Author E-Mail Address: rhbeigi@ut.ac.ir