

## بررسی شاخص‌های مهم خشک شدن انگور در روش خشک کردن با جریان هوای گرم به کمک شبکه‌های عصبی مصنوعی

ناصر بهروزی خزایی<sup>۱</sup>، رضا امیری چایجان<sup>۲</sup>، تیمور توکلی هاشجین<sup>۳</sup> و محمد هادی خوش تقاضا<sup>۳</sup>

### چکیده

در این پژوهش پیش‌بینی زمان خشک شدن انگور و پارامترهای کیفی محصول نهایی (کشمش) در خشک کردن به روش جریان هوای گرم به کمک شبکه‌های عصبی مصنوعی انجام شد. دمای هوا، سرعت جریان هوا و نوع آماده‌سازی اولیه انگور از پارامترهای مهم در خشک کردن انگور با خشک کن‌های جریان هوای گرم می‌باشد که به عنوان پارامتر مستقل برای شبکه‌های عصبی مصنوعی در نظر گرفته شد. برای ایجاد الگوهای آموزش و ارزیابی فرایند، آزمایش‌های خشک کردن به کمک یک خشک کن آزمایشگاهی انجام گرفت. با به دست آمدن زمان خشک شدن و کیفیت محصول نهایی از چندین شبکه عصبی مصنوعی با الگوریتم یادگیری لونیگ-مارکوارت برای آموزش الگوها استفاده شد. نتایج نشان داد که شبکه بهینه‌ی پس انتشار المان با توپولوژی ۳-۶-۳ و الگوریتم یادگیری لونیگ-مارکوارت با تابع آستانه سیگموئید لگاریتمی قادر است زمان خشک شدن و پارامترهای کیفی محصول نهایی (شاخص روشنایی و شاخص نسبت قرمزی به زردی) را به ترتیب با ضرایب تعیین ۰/۹۹۱، ۰/۹۷۳، ۰/۹۹۳ و با خطاهای حقیقی ۰/۱۶۵، ۰/۳۹، ۰/۰۲۶ پیش‌بینی کند. اعمال خطا به متغیرهای ورودی شبکه‌ی بهینه نشان داد که عملکرد شبکه به دلیل تولید خطای آموزش کمتر از خطای ورودی، به‌طور مناسبی قادر به پیش‌بینی مقادیر خروجی می‌باشد.

واژه‌های کلیدی: انگور، پیش‌بینی هوشمند، شبکه‌ی المان، زمان خشک کردن، شبکه‌ی عصبی مصنوعی

۱. دانشجوی کارشناسی ارشد مهندسی مکانیک ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران

۲. استادیار، گروه مکانیک ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان

۳. به‌ترتیب استاد و دانشیار مهندسی ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه تربیت مدرس، تهران

منحنی خشک کردن محصولات کشاورزی و غذایی در چرخه فرآوری بر مبنای روش حل معادلات انتقال جرم و حرارت و روش‌های آماری یا معادلات رگرسیونی است. فرض اصلی مدل‌های مذکور بر آن است که داده‌های آزمایشی بیانگر واقعیت پدیده هستند و به کمک معادلات جبری بیان می‌شود. از آنجا که پیش‌بینی شاخص‌های کیفی شامل چند متغیر ورودی و خروجی است، تحلیل آماری یا ریاضی آن‌ها مشکل و تفسیر آن‌ها دشوار است، از این رو باعث پیچیده شدن مسئله می‌شود. دقت پیش‌بینی روش‌های آماری اغلب به وسیله RMSE،  $\chi^2$  و  $R^2$  بیان می‌شود. ابتدا مدل ایجاد می‌شود و دیگر نمی‌توان دقت مدل برازش شده را افزایش داد. سیستمی در پیش‌بینی دقیق‌تر عمل می‌کند که از الگوهای ورودی بیاموزد، زیرا قابلیت اعتماد بیشتری در طی زمان خواهد داشت و قابلیت سازگاری آن با تغییرات پیش‌بینی نشده در داده‌ها بیشتر خواهد بود. شبکه‌های عصبی مصنوعی به علت داشتن چنین قابلیت‌هایی در بین روش‌های ناپارامتری از محبوبیت بالایی برخوردار است. علت اصلی محبوبیت شبکه‌های عصبی مصنوعی قابلیت تعمیم و تقریب‌زنی آن است (سینکو، ۱۹۸۹؛ هورنیک و همکاران، ۱۹۸۹). یکی از قابلیت‌های مهم در کاربرد شبکه‌های عصبی مصنوعی آن است که هیچ پیش‌شرطی را در پدیده و مکانیزم مربوطه برای ارتباط بین متغیرها در نظر نمی‌گیرد (بیشاپ، ۱۹۹۴). از این رو شبکه‌های عصبی می‌تواند به‌عنوان جایگزین مناسب برای مدل‌سازی تجربی متداول بر مبنای رگرسیون چند جمله‌ای و خطی باشد.

شبکه‌ی عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری<sup>۱</sup> و با استفاده از پردازشگرهایی بنام نرون<sup>۲</sup> تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های پنهان<sup>۳</sup>، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش

خشک کردن یکی از قدیمی‌ترین راه‌های نگه‌داری مواد غذایی است که برای جلوگیری از فساد مواد غذایی با کاهش دادن محتوای رطوبتی منجر به کاهش یا توقف فعالیت‌های آنزیمی یا میکروبی می‌شود و از طرف دیگر محصولات با وزن و حجم کم تولید می‌شوند که جابه‌جایی و فرآوری آنها آسان‌تر می‌باشد.

کشمش یکی از محصولات صادراتی کشاورزی ایران است که در مقابل صادرات انگور از ارزش اقتصادی بالایی برخوردار است (نادی، ۱۳۸۴). بیشتر کشمش تولیدی در ایران به این صورت به دست می‌آید که انگور بعد از چیده شدن و شسته شدن در محلول تیزابی، در محلی که اصطلاحاً بارگاه گفته می‌شود، به صورت یک-نواخت پهن می‌شود. در این روش خشک کردن به خاطر معایبی هم‌چون طولانی شدن زمان خشک شدن، اضافه شدن گرد و خاک، حمله آفات و شرایط نامعلوم هوا کیفیت کشمش تولیدی کاهش می‌یابد. به همین دلیل از نظر ارزش کشمش صادراتی، ایران در رده دهم جهان قرار دارد. علاوه بر آن در این روش خشک کردن تهیه کشمش محدود و نیاز به نیروی کار زیادی دارد (زمردی و دولتی‌بانه، ۱۳۸۲). در اکثر کشورها برای جلوگیری از آلودگی‌ها و سرعت بخشیدن به عمل خشک شدن، خشک کردن با خشک‌کن‌های صنعتی (خشک‌کن‌های با جریان هوای گرم و خورشیدی) جای‌گزین روش‌های سنتی گردیده است. استفاده از خشک‌کن‌های جریان هوای گرم به‌خصوص برای محصولاتی مانند انگور که زمان زیادی برای خشک شدن نیاز دارند، سبب تسریع در فرایند خشک شدن شده و امکان رعایت شرایط بهداشتی را فراهم می‌آورد. هم‌چنین باعث یک‌نواختی محصول کشمش از نظر رطوبت و کیفیت نهایی می‌شود، لذا استفاده از آن اجتناب ناپذیر است (کاراتانوس و بلیسوتیس، ۱۹۹۷؛ طغرل و پهلوان، ۲۰۰۴).

یکی از روش‌های موثر در طراحی و بهینه‌سازی خشک‌کن‌ها، پیش‌بینی و مدل کردن فرآیند خشک کردن می‌باشد. مهم‌ترین بخش فرآیند خشک کردن، پیش‌بینی زمان خشک کردن و ارزیابی کیفیت محصول نهایی است. روش‌های متداول تحلیل پارامترهای کیفی و

1. Learning  
2. Neuron  
3. Hidden Layer

کردند. متغیرهای مستقل در این پژوهش به عنوان ورودی به شبکه عبارت بودند از رطوبت نسبی هوای محیط، دمای هوای محیط، سرعت هوای ورودی، عمق بستر شلتوک، دمای هوای ورودی، رطوبت اولیه و نهایی و ضریب تبدیل شلتوک به عنوان خروجی شبکه در نظر گرفته شد. نتایج آن‌ها نشان داد که شبکه پس انتشار پیشخور با توپولوژی ۱-۷-۷-۷ با الگوریتم یادگیری لونیبرگ-مارکوارت با تابع آستانه تانژانت سیگموئیدی قادر است راندمان تبدیل شلتوک را به برنج با ضریب تعیین ۹۶/۵۵ و خطای متوسط مطلق ۰/۰۱۹ در شرایط مختلف خشک کردن شلتوک پیش‌بینی کند.

با توجه به ضرورت‌های بیان شده، هدف این پژوهش عبارت است از: ایجاد ارتباط بین متغیرهای مستقل موثر در فرایند خشک کردن انگور با شاخص‌های کیفی و زمان خشک کردن در شرایط آزمایشگاهی و یافتن شبکه‌ی عصبی با توپولوژی مناسب به منظور پیش‌بینی متغیرهای مستقل در خشک کردن انگور و ارائه ماتریس ضرایب وزنی شبکه‌ی بهینه.

### مواد و روش‌ها

#### خشک کن آزمایشگاهی و تجهیزات مورد استفاده

در این پژوهش برای انجام آزمایش‌ها از یک خشک‌کن آزمایشگاهی با جریان هوای اجباری استفاده شد. این خشک‌کن قابلیت کنترل دما و سرعت‌های مختلف را دارد. محفظه خشک‌کن در ابعاد  $1 \times 1 \times 1$  متر و سینی خشک‌کن در ابعاد  $0.9 \times 0.9 \times 0.9$  متر با شبکه سیمی  $8 \times 8$  میلی‌متر ساخته شده است. جریان هوا به صورت عمودی به محصول برخورد می‌کند. این خشک‌کن مجهز به یک سیستم توزین A&D, GF-300, Japan با دقت  $0.01$  گرم برای وزن کردن پیوسته محصول در حال خشک شدن (با فاصله زمانی ۳۰ دقیقه) می‌باشد که توسط یک اتصال سریال RS-232C به رایانه متصل شده و عمل داده‌برداری توسط برنامه‌ی نگارش شده در محیط ویژوال بیسیک در رایانه انجام می‌شود (شکل ۱). در این خشک‌کن از یک اینورتر برای کنترل دور فن و در نتیجه کنترل سرعت جریان هوا و از یک کنترل کننده دما از نوع Samwon Eng, SU-105IP با

می‌بیند. آموزش فرایندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دست‌یابی به این شرایط فرایند یادگیری محقق شده است. این وزن‌ها حافظه و دانش شبکه را بیان می‌کنند. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها به کار رود (هریستوف، ۱۹۹۸).

ژانگ و همکاران (۲۰۰۲) برای پیش‌بینی شاخص‌های انرژی مصرفی، ترک دانه، رطوبت نهایی، آهنگ دفع رطوبت<sup>۱</sup>، شدت خشک شدن در فرآیند خشک کردن شلتوک تحت تاثیر چهار پارامتر ورودی ضخامت لایه برنج، دبی هوای گرم، دمای هوا و زمان خشک شدن از شبکه عصبی استفاده کردند. مدل شبکه عصبی بهینه در این بررسی با ۸ و ۵ نرون به ترتیب در اولین و دومین لایه پنهان با الگوریتم پس انتشار خطا حاصل شد. از نظر میزان دقت، مدل به دست آمده که با بین ۲ تا ۸/۳٪ برای شش پیش‌بینی مختلف با میانگین ۴/۴٪ تغییر می‌کرد.

صبلانی و رحمان (۲۰۰۳) از شبکه عصبی مصنوعی برای پیش‌بینی قابلیت هدایت حرارتی مواد غذایی به عنوان تابعی از محتوای رطوبتی، دما و تخلخل ظاهری استفاده کردند. ساختارهای مختلفی از شبکه MLP<sup>۲</sup> با الگوریتم پس انتشار خطا بر روی داده‌های آزمایش برای به دست آوردن شبکه‌ای با ساختار مناسب مورد استفاده قرار گرفت. بهترین شبکه با دو لایه پنهان که در هر کدام ۴ نرون بود، به دست آمد. شبکه به دست آمده قادر بود قابلیت هدایت حرارتی را با دقت میانگین خطای نسبی ۱۲/۶٪ و میانگین خطای مطلق ۰/۰۸۱ پیش‌بینی کند.

خوش تقاضا و همکاران (۱۳۸۶) برای پیش‌بینی ضریب تبدیل شلتوک به برنج سفید در خشک کردن به روش بستر ثابت از شبکه‌های عصبی مصنوعی استفاده

1. Moisture Removal Rate
2. Multilayer Perceptron

سرعت هوا در سه سطح ۰/۵، ۱ و ۱/۵ متر بر ثانیه و سه تیمار آماده‌سازی شاهد (بدون تیزاب)، ۰/۲/۵٪ کربنات پتاسیم + ۰/۱٪ روغن سبزه (محلول تیزابی نوع ۱) و ۰/۵٪ سود + ۰/۱٪ روغن سبزه (محلول تیزابی نوع ۲) استفاده شد. با توجه به مطالعات انجام گرفته، رطوبت نسبی هوا کم‌ترین تاثیر را در خشک کردن انگور (فقط در حدود ۷-۵٪) دارد (پنگوان و همکاران، ۲۰۰۰). در این پژوهش، رطوبت نسبی هوا در حین آزمایش‌ها در حدود ۵۰٪ بود. این سطوح دما و سرعت تقریباً تمام شرایط هوا را تا حد امکان پوشش می‌دهد. لایه مومی شکل بر روی انگور، نفوذ آب از محصول به عامل خشک‌کننده (هوا گرم) را محدود می‌سازد و زمان خشک شدن را افزایش می‌دهد. آماده‌سازی، باعث از بین رفتن و یا تغییر ترکیبات لایه مومی شکل در سطح انگور شده و نفوذ-پذیری پوست را نسبت به انتقال رطوبت تحت تاثیر قرار می‌دهد و همچنین روی کیفیت محصول نهایی تاثیر بسزایی دارد (ضرابی، ۱۳۷۷؛ تولاسیداس و همکاران، ۱۹۹۶). برای هر آزمایش حدود ۳kg از انگورهای شسته شده را وزن کرده و در داخل یک سبد توری قرار می‌دهیم. سپس آن‌ها را با سبد داخل محلول آماده‌سازی که از قبل آماده شده است، فرو برده و به مدت یک دقیقه نگه می‌داریم. بعد از این که نمونه‌ها را از داخل محلول آماده سازی خارج کردیم، حبه‌های روی خوشه را با دقت تمام روی سینی قرار می‌دهیم تا صدمه‌ای به حبه‌ها وارد نشود. بعد از این که تمام حبه‌ها را روی سینی توری به صورت یکنواخت پخش می‌کنیم و سینی توری را که حبه‌ها بر روی آن قرار گرفته‌اند در داخل دستگاه خشک‌کن که از بابت شرایط اولیه، دستگاه به حالت پایدار رسیده است قرار می‌دهیم و سینی توری را به چنگک ترازوی بالای خشک کن وصل می‌کنیم.

در صنایع غذایی برای تولید هر محصول غذایی با کیفیت مطلوب، مهم‌ترین اصل داشتن ماده اولیه مناسب می‌باشد (زمردی و دولتی بانه، ۱۳۸۲). نوع واریته انگور در تهیه کشمش با کیفیت مرغوب بسیار موثر است. در این پژوهش نمونه‌های مورد نیاز از انگور سفید بی‌دانه از شهرستان ارومیه تهیه گردید. نمونه‌ها بعد از انتقال به آزمایشگاه در دمای ۴°C نگهداری شدند. برای هر آزمایش از ۳ کیلوگرم انگور استفاده شد.

دقت ۰/۱°C برای کنترل دما استفاده شد. برای اندازه‌گیری دبی هوای خروجی از محفظه خشک‌کن، از یک سرعت‌سنج پره‌ای Lutron A-M-4202 ساخت کشور تایوان با دقت ۰/۲± استفاده شد. کوره خشک‌کن از ۲۰ المنت ۵۰۰ واتی ساخته شده که هوا بعد از عبور از بین المنت‌های حرارتی وارد بخش خطی‌کننده جریان شده تا هوایی که به نمونه‌های آزمایشی می‌رسد به صورت یکسان در سطح مقطع خشک‌کن پخش شود. در شکل ۲ چهار نمونه از منحنی‌های خشک‌شدن انگور در دماهای ۴۰ تا ۷۰°C و سرعت هوای ۱ m/s آورده شده است که با تیمار آماده سازی ۰/۲/۵٪ کربنات پتاسیم+ ۰/۱٪ روغن سبزه (محلول تیزابی نوع ۱) آماده شده است. زمان غوطه‌وری انگورها در محلول‌های تیزابی یک دقیقه بود.

#### اندازه گیری پارامترهای کیفی محصول نهایی

رنگ، یک ویژگی کیفی عمده در میوه‌های خشک‌شده است و در طی خشک‌کردن به علت برخی واکنش‌های شیمیایی و بیوشیمیایی، تغییر می‌کند. در حقیقت رنگ و ظاهر محصول بیش از سایر پارامترهای کیفی (خواص مکانیکی، مواد غذایی و محتوای رطوبت) تحت تاثیر شرایط هوا و نوع آماده‌سازی اولیه قرار می‌گیرد و در تعیین قیمت نهایی محصول نقش بسزایی دارد. برای ارزیابی رنگ به عنوان بارزترین شاخص در مقبولیت محصول نهایی از سه شاخص هانترلب (Minolta, cr-300. chroma, USA) استفاده شد (ریوا و همکاران، ۱۹۸۶؛ دویماز و مهمت، ۲۰۰۲). پارامتر L برای بیان روشنایی، پارامتر a برای بیان قرمزی و پارامتر b برای بیان زردی یک محصول استفاده می‌شود. برای بیان کیفیت محصولات از نظر رنگ، از شاخص‌های L و نسبت a/b استفاده می‌شود (آگویلا و همکاران، ۱۹۸۷).

#### سطوح آزمایشی و آماده سازی محصول

دما، سرعت هوا و آماده‌سازی اولیه از عوامل موثر در فرآیند خشک‌کردن انگور است. در این پژوهش دمای هوا در چهار سطح ۴۰، ۵۰، ۶۰ و ۷۰ درجه سلسیوس،

است که به دلیل افزایش پیوندهای بین‌نرونی، شبکه‌ی به‌کار رفته پیچیده‌تر می‌شود، زیرا حجم محاسبات آن افزایش می‌یابد (دیموت و بیل، ۲۰۰۳).

ج) شبکه عصبی آلمان<sup>۳</sup> (EN): این شبکه یکی از شبکه‌های بازگشتی است و جزء شبکه‌های پس انتشار به شمار می‌رود که یک پیوند پس‌خوردی از خروجی لایه‌ی پنهان به ورودی آن دارد. این مسیر بازخوردی برای شبکه‌ی آلمان این امکان را فراهم می‌کند تا الگوهای موقتی را مانند الگوهای دائمی فرا بگیرد (آلمان، ۱۹۹۰). فاصله الگوریتم یادگیری به کار رفته برای شبکه‌ی آلمان نیز، پس انتشار است و توابع آستانه و الگوریتم‌های به کار رفته برای شبکه آلمان نیز مانند دو شبکه اخیر است.

با در نظر گرفتن سه عامل ورودی دمای هوا، سرعت هوا و نوع آماده‌سازی اولیه به‌کار رفته، زمان خشک شدن و کیفیت محصول نهایی بعد از هر آزمایش حاصل می‌شود. شبکه عصبی با سه نرون لایه ورودی (دمای هوا، سرعت هوا، نوع آماده‌سازی) و سه نرون لایه خروجی (زمان خشک شدن، شاخص روشنایی، شاخص نسبت قرمز به زردی) طراحی شد. شکل ۳، توپولوژی شبکه عصبی مورد نظر و پارامترهای ورودی و خروجی برای شبکه مذکور را نشان می‌دهد. نرم‌افزار Neural Networks Toolbox MATLAB 7 (ver. 4.01) برای طراحی و ارزیابی شبکه‌های عصبی مصنوعی مختلف استفاده شد. توابع آستانه مختلفی برای یافتن حالت بهینه آن مورد ارزیابی قرار گرفت که عبارتند از: تابع سیگموئید لگاریتمی (LOGSIG) و تابع تانژانت سیگموئیدی (TANSIG).

برای آموزش شبکه، ابتدا داده‌ها به‌طور تصادفی به نسبت تقریبی ۳ به ۱ تقسیم شدند، طوری که ۲۶ داده برای آموزش و ۱۰ داده برای ارزیابی شبکه استفاده شد. برای یافتن شبکه عصبی با توپولوژی مناسب به کمک الگوریتم‌های آموزشی، از معیار خطای مربعات میانگین استفاده می‌شود که هدف کمینه شدن خطای مذکور است و از رابطه زیر به‌دست می‌آید:

### 3. Elman Network

محتوای قند انگور (شاخص بریکس) به کمک رفاکتومتر دستی (Erma-optical, works, LTD, Japan)، قطر حبه‌های انگور به‌وسیله کولیس با دقت ۰/۱ میلی‌متر و محتوای رطوبت اولیه انگور به روش آون تحت خلا به مدت ۸ ساعت و دمای ۷۰°C تعیین گردید (AOAC, 1990). شاخص بریکس برای حبه‌های انگور برابر ۱ ± ۲۳ و درصد رطوبت اولیه انگور و محصول نهایی بر پایه‌تر به ترتیب برابر ۷۵ ± ۲ و ۱۷/۵ ± ۰/۸، و قطر متوسط حبه‌های انگور، برابر ۱ ± ۱ mm بدست آمد.

### شبکه‌های عصبی مصنوعی به کار رفته و معیارهای ارزیابی

به منظور پردازش داده‌ها، از چندین شبکه استفاده شد که عبارتند از:

الف) شبکه‌های پس انتشار پیشخور<sup>۱</sup> (FFBP): ساختار ایستایی (غیر وابسته به زمان) این شبکه در مسائل مهندسی و محاسبات علمی کاربرد دارد (هریستوف، ۱۹۹۸). نرون‌ها که عناصر پردازشگر سیگنال هستند از طریق اتصالات سیناپسی بین لایه‌ای پیشخور به هم متصل می‌شوند. ارتباط ورودی-خروجی ممکن است به وسیله توابع نگاشت (توابع آستانه) غیرخطی انجام شود. الگوریتم پس‌انتشار خطا روش اصلی برای به‌هنگام‌سازی وزن‌های شبکه‌ی FFBP برای انجام محاسبات است. لایه اول، لایه‌ی ورود اطلاعات است و هیچ‌گونه پردازشی در این لایه انجام نمی‌شود. لایه آخر لایه‌ی خروجی شبکه بوده و کاربر یا سیستم کنترل می‌تواند اطلاعات پردازش‌شده را دریافت کند.

ب) شبکه‌های پس انتشار پیشرو<sup>۲</sup> (CFBP): این شبکه‌ها نیز مانند شبکه‌ی پس انتشار پیشخور از الگوریتم پس انتشارخطا برای به‌هنگام‌سازی وزن‌ها استفاده می‌کند ولی خصوصیات اصلی شبکه‌ی مذکور این است که نرون‌های هر لایه به همه‌ی نرون‌های لایه‌های قبل متصل است. توابع آستانه و الگوریتم‌های به‌کار گرفته شده برای شبکه‌ی پس انتشار پیشرو مشابه شبکه‌ی پس‌انتشار پیشخور است. نکته قابل توجه این

1. Feed Forward Back Propagation
2. Cascade Forward Back Propagation

لایه پنهان و مرحله دوم، استفاده از توابع TANSIG و LOGSIG در لایه‌ها. در شرایط یک لایه پنهان در شبکه FFBP، توپولوژی‌های مختلف در اکثر موارد دچار وراآموزی<sup>۱</sup> شدند یا قادر به یادگیری داده‌های آموزشی نبودند (جدول ۱). در جدول مذکور بهترین نتایج مربوط به ترکیب شبکه FFBP با توپولوژی‌های مختلف و توابع مختلف فعال سازی ارائه شده است. جدول‌های ۲ و ۳ نیز برای شبکه‌های CFBP و LM ارائه شده است. از نتایج ارائه شده در جدول ۱ می‌توان دریافت که شبکه FFBP با یک لایه پنهان و تابع فعال‌سازی لگاریتم سیکموئید (LOGSIG) نسبت به تابع فعال‌سازی تانژانت هایپربولیک سیکموئید (TANSIG) نتایج بهتری ارائه داد. زیرا به‌طور متوسط، خطای کمتری برای پارامترهای زمان (۲/۰۳) و شاخص‌های رنگ (۰/۴۵) و  $E_{MS}$  (۰/۰۵) ارائه داد، با توجه به این‌که خطای  $E_{MS}$  کمی بیشتر (۰/۰۰۵) بود. در این شرایط بهترین نتیجه برای توپولوژی ۳-۷-۳ حاصل شد. در شبکه FFBP با دو لایه پنهان، تابع آستانه‌ی LOGSIG، نسبت به تابع آستانه‌ی TANSIG نتایج بهتری ارائه داد، زیرا خطای  $E_{MS}$  میانگین مطلق، کمتر از بهترین مقادیر ارائه شده توسط تابع آستانه‌ی TANSIG بود. بهترین توپولوژی، برای ۳-۴-۵-۳ به دست آمد که در ۲۶ چرخه‌ی تکرار حاصل شد. با توجه به نتایج حاصله، توپولوژی سه لایه نسبت به توپولوژی چهار لایه نتایج بهتری ارائه داد. لذا در این بخش توپولوژی ۳-۷-۳ با تابع آستانه‌ی LOGSIG انتخاب می‌شود.

در شرایط یک لایه پنهان در شبکه‌ی CFBP به همراه تابع فعال سازی LOGSIG بهترین نتیجه برای توپولوژی ۳-۸-۳ به دست آمد. زیرا خطاهای آموزش (۰/۰۰۰۰۸۵) و میانگین مطلق آن نسبت به توپولوژی‌های دیگر، کم‌ترین مقدار مختلف در ۲۴ چرخه‌ی آموزش به دست آمد (جدول ۲). نتایج این توپولوژی از بهترین نتیجه‌ی مربوط به توپولوژی‌های چهار لایه‌ی با تابع فعال‌سازی LOGSIG بهتر است که مربوط به ۳-۷-۴-۳ است. برای شبکه‌ی CFBP و تابع آستانه TANSIG نیز بهترین نتیجه مربوط به توپولوژی

$$E_{MS} = \frac{\sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2}{M \times N} \quad (1)$$

که در آن  $E_{MS}$  خطای مربعات میانگین در مرحله آموزش،  $S_{ip}$  خروجی شبکه در نرون  $i$ ام و الگوی  $p$ ام،  $T_{ip}$  خروجی هدف در نرون  $i$ ام و الگوی  $p$ ام،  $N$  تعداد نرون‌های لایه خروجی و  $M$  تعداد الگوهای آموزشی است. برای بهینه کردن شبکه‌های یافته شده در مرحله قبل از معیار ضریب تعیین ( $R^2$ )، خطای مطلق میانگین و انحراف معیار خطای میانگین مطلق استفاده می‌شود که به صورت رابطه زیر تعریف می‌شوند:

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

$$E_{MA} = \frac{1}{n} \sum_{k=1}^n |S_k - T_k| \quad (3)$$

$$SD_{EMA} = \sqrt{\frac{\sum_{k=1}^T |S_k - T_k| - |S_k - T_k|}{T-1}} \quad (4)$$

که در آن  $E_{MA}$  خطای مطلق میانگین و  $SD_{EMA}$  انحراف معیار خطای مطلق میانگین است.  $n$  تعداد الگوهای آموزشی و  $k$  شماره الگو است. برای افزایش دقت و سرعت شبکه عصبی مصنوعی، داده‌های ورودی و خروجی به کمک رابطه زیر به شکل هنجار شده در محدوده [۰، ۱] تبدیل می‌شود:

$$X_n = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

که  $X_n$  مقدار هنجار شده،  $X_i$  مقدار واقعی،  $X_{\min}$  کمینه مقادیر واقعی و  $X_{\max}$  بیشینه مقادیر واقعی است.

ابتدا تعداد لایه‌های پنهان و تعداد نرون‌های هر لایه، به روش آزمون و خطا مورد بررسی قرار گرفت. پس از انتخاب شبکه مناسب، تعداد لایه پنهان و نرون‌های لایه پنهان و تابع آستانه، مقادیر مناسب تعداد تکرار باید انتخاب شود.

## بحث و نتایج

ترکیب دو مرحله برای بررسی تاثیر توابع فعال‌سازی مختلف برای بهینه‌سازی شبکه‌های مورد استفاده به کار گرفته شد: مرحله اول، استفاده از یک و دو

1. Over Training

می توان دریافت که به طور متوسط شبکه های سه لایه به همراه تابع آستانه ی LOGSIG بهترین نتایج را ارائه داده اند. بهترین عملکرد، مربوط به شبکه ی EN است که با توپولوژی ۳-۶-۳ و تابع آستانه ی LOGSIG حاصل شد. خطاهای مطلق برای سه متغیر خروجی به ترتیب ۱/۶۵، ۰/۳۹ و ۰/۲۶ به دست آمد که در ۲۶ چرخه ی آموزش حاصل شد. چگونگی یادگیری شبکه ی مذکور در شکل ۴ نشان داده شده است. منحنی های یادگیری آموزش و ارزیابی بیانگر یادگیری مناسب شبکه و احتمال کم وراموزی شبکه است، زیرا اختلاف کمی بین این دو منحنی مشاهده می شود. این امر بیانگر عدم وراموزی شبکه و دقت مناسب در آزمایش ها است. ماتریس های بین لایه ها و بایاس ها برای توپولوژی بهینه عبارت است از:

$$iw\{2,1\} = \begin{bmatrix} 10/10 & 1/25 & -0/14 \\ 2/54 & 2/40 & 0/61 \\ 3/96 & 2/36 & -0/58 \\ -1/75 & 6/28 & -0/57 \\ -3/84 & -1/59 & -1/42 \\ 2/36 & -0/95 & 2/30 \end{bmatrix}$$

(وزن بین لایه های ۱ و ۲)

سه لایه است. به طوری که توپولوژی ۳-۵-۳ بهترین نتیجه را با خطای آموزش ۰/۰۰۰۱۵ و خطاهای مطلق میانگین کمتر ارائه داد. با توجه به نتایج ذکر شده برای شبکه ی CFBP، بهترین ترکیب مربوط به توپولوژی ۳-۸-۳ است که دارای تابع فعال سازی LOGSIG است.

آخرین شبکه ای که برای تخمین شاخص های خشک شدن انگور به کار رفت، شبکه ی المان (EN) است که مراحل انتخاب بهترین توپولوژی و تابع آستانه، برای آن نیز انجام شد. نتایج نشان داد که توپولوژی ۳-۶-۳ به همراه تابع فعال سازی LOGSIG بهترین نتیجه را بین توپولوژی های سه و چهار لایه دارد. زیرا بالاترین مقادیر  $R^2$  و کم ترین مقادیر خطاهای مطلق برای متغیرهای خروجی ایجاد کرد. خطاهای آموزش آن ۰/۰۰۰۴۷ است که در ۲۶ چرخه به دست آمد. کاربرد تابع آستانه ی TANSIG نیز منجر به انتخاب بهترین توپولوژی ۳-۴-۴ شد. زیرا در بین توپولوژی های مختلف، بهترین نتیجه را ارائه داد. با توجه به نتایج حاصله برای شبکه ی EN، بهترین ترکیب مربوط به توپولوژی ۳-۶-۳ است که دارای تابع فعال سازی LOGSIG است.

با توجه به بهترین نتایج به دست آمده برای شبکه های مورد استفاده در این پژوهش و مقایسه ی آنها،

$$iw\{2,2\} = \begin{bmatrix} -0/38 & -1/98 & -0/97 & -0/79 & 1/18 & -2/60 \\ -0/35 & -3/70 & -2/48 & 2/08 & 1/90 & 0/40 \\ -0/43 & 1/68 & 1/09 & 2/55 & -2/66 & 3/75 \\ -0/65 & 1/11 & 1/73 & 3/10 & 2/99 & -1/22 \\ 3/25 & 3/91 & -1/00 & 2/79 & 0/56 & 1/26 \\ -3/67 & 0/39 & -3/64 & -0/98 & 0/98 & -0/80 \end{bmatrix}$$

(وزن اتصال های بازخوردی لایه ۲)

$$iw\{3,2\} = \begin{bmatrix} 5/90 & -7/30 & 0/81 & 0/74 & 6/47 & 4/88 \\ -4/60 & 6/65 & -6/12 & 3/64 & 1/04 & 4/68 \\ 5/87 & -5/80 & -3/16 & 3/00 & -0/56 & 3/53 \end{bmatrix}$$

(وزن بین لایه های ۲ و ۳)

جدول ۴ آورده شده است. کم‌ترین زمان خشک شدن نمونه‌های ارزیابی ۱۴ ساعت بود که مربوط به تیزاب ۲/۵٪ کربنات پتاسیم + ۱٪ روغن سبزه است و دارای خطای پیش بینی ۰/۱۴ ساعت است. در حالی که بیشترین زمان خشک شدن نمونه‌های ارزیابی ۹۴ ساعت بود که مربوط به نمونه شاهد است و دارای خطای پیش بینی ۶/۹۹ ساعت است. میانگین خطای پیش‌بینی زمان خشک‌شدن حدود ۱/۶۵ به‌دست آمد. با توجه به اینکه میانگین زمان الگوهای ارزیابی حدود ۳۷/۸۲ ساعت است، خطای میانگین ۱/۶۵ نسبت به آن مناسب است (۴/۳۶٪). خطای نسبی میانگین پیش بینی پارامترهای  $t$  و  $a/b$  به ترتیب ۲٪ و ۲/۹۹٪ به‌دست آمد. تمامی خطاهای به‌دست آمده برای سه پارامتر پیش بینی شده زیر ۵٪ است که بیانگر عملکرد مناسب شبکه‌ی بهینه است.

به‌منظور بررسی پایداری شبکه‌ی مذکور نیز خطایی تصادفی با دامنه‌ای برابر با  $\pm 10\%$  درصد دامنه‌ی الگوهای ورودی به آن‌ها افزوده شد. نتایج نشان داد که شبکه مذکور قابلیت اعتماد بالایی در مواجهه با الگوهای ناشناخته دارد. زیرا مقادیر  $E_{MS}$ ،  $R^2$ ، خطای  $E_{MA}$  و انحراف معیار آن تغییرات ناگهانی نداشتند. روند مذکور برای الگوهای اعتبارسنجی نیز مشاهده می‌شود (جدول ۵).

$$b\{2\} = \begin{bmatrix} -0/50 \\ -6/16 \\ -0/33 \end{bmatrix} \text{ (بایاس لایه ۳)}$$

$$b\{1\} = \begin{bmatrix} -6/56 \\ -3/10 \\ -7/23 \\ -0/67 \\ -2/28 \\ 7/87 \end{bmatrix} \text{ (بایاس لایه ۲)}$$

ماتریس‌های فوق با توجه به توپولوژی بهینه ۳-۳، به‌دست آمده و خروجی شبکه‌ی بهینه است. ماتریس  $w\{2,1\}$  یک ماتریس  $6 \times 3$  است زیرا شش نرون در لایه پنهان و سه نرون ورودی وجود دارد. با توجه به اینکه شبکه بهینه (شبکه‌ی المان) سه لایه بوده و اتصالات بازخوردی از لایه پنهان دارد، لذا ماتریس بازخوردی با توجه به تعداد شش نرون در لایه پنهان،  $6 \times 6$  است. ماتریس  $w\{3,2\}$  نیز ماتریس لایه‌ی پنهان به لایه‌ی خروجی است که  $3 \times 6$  می باشد. از ضرایب ماتریس حاصله، می‌توان برای ایجاد ارتباط بین ورودی‌ها و خروجی‌های شبکه استفاده کرد و برای ساخت سیستم‌های کنترلی برای خشک‌کن‌های انگور نیز می‌توان از آن بهره برد.

مقادیر پیش‌بینی شده متغیرهای خروجی  $L, t$  و  $a/b$  به همراه مقادیر آزمایشی و خطای واقعی آن‌ها در



جدول ۱: بهترین مقادیر خطای آموزش و سایر معیارهای ارزیابی برای شبکه FFBP در شرایط مقادیر مختلف تعداد لایه‌ها و توابع آستانه

چرخه آموزش	$SD_{EMA}$ t) L (a/b)	$E_{MA}$ t) L (a/b)	$R^2$ t) L (a/b)	$E_{MS}$	تعداد لایه‌ها و نرون‌ها	تابع فعال‌سازی
۲۸	۱/۱۰	۲/۰۳	۰/۹۹۳۳	۰/۰۰۰۵۰	۳-۷-۳	LOGSIG
	۰/۳۸	۰/۴۵	۰/۹۷۱۱			
	۰/۰۴۵	۰/۰۵۰	۰/۹۷۴۷			
۲۶	۲/۲۱	۲/۷۵	۰/۹۸۸۸	۰/۰۰۰۴۷	۳-۵-۴-۳	LOGSIG
	۰/۲۳	۰/۳	۰/۹۸۷۶			
	۰/۰۴۰	۰/۰۴۴	۰/۹۷۷۱			
۳۴	۱/۶۶	۲/۴۵	۰/۹۸۷۹	۰/۰۰۰۴۰	۳-۶-۳	TANSIG
	۰/۳۱	۰/۴۹	۰/۹۶۸۹			
	۰/۰۴۸	۰/۰۴۳	۰/۹۷۶۹			
۲۱	۲/۸۰	۲/۸۴	۰/۹۸۸۴	۰/۰۰۰۵۵	۳-۶-۴-۳	TANSIG
	۰/۳۸	۰/۴۶	۰/۹۷۲۰			
	۰/۰۵۰	۰/۰۵۱	۰/۹۶۵۷			

جدول ۲: بهترین مقادیر خطای آموزش و سایر معیارهای ارزیابی برای شبکه CFBP در شرایط مقادیر مختلف تعداد لایه‌ها و توابع آستانه

چرخه آموزش	$SD_{EMA}$ t) L (a/b)	$E_{MA}$ t) L (a/b)	$R^2$ t) L (a/b)	$E_{MS}$	تعداد لایه‌ها و نرون‌ها	تابع فعال‌سازی
۲۴	۱/۹۶	۱/۸۷	۰/۹۹۰۳	۰/۰۰۰۰۸۵	۳-۸-۳	LOGSIG
	۰/۳۴	۰/۴۲	۰/۹۷۲۹			
	۰/۰۵۱	۰/۰۴۶	۰/۹۷۶۳			
۲۰	۱/۷۰	۲/۰۷	۰/۹۸۹۸	۰/۰۰۰۰۷۳	۳-۷-۴-۳	LOGSIG
	۰/۱۸	۰/۲۵	۰/۹۹۰۵			
	۰/۰۴۸	۰/۰۴۷	۰/۹۷۲۷			
۲۸	۱/۸۳	۲/۱۲	۰/۹۸۸۹	۰/۰۰۰۰۱۵	۳-۵-۳	TANSIG
	۰/۴۴	۰/۴۷	۰/۹۶۹۱			
	۰/۰۳۳	۰/۰۴۷	۰/۹۷۷۱			
۱۶	۱/۵۸	۲/۲۱	۰/۹۹۳۰	۰/۰۰۰۰۵۶	۳-۶-۴-۳	TANSIG
	۰/۴۹	۰/۶۴	۰/۹۳۸۰			
	۰/۰۴۸	۰/۰۴۷	۰/۹۷۹۹			

جدول ۳: بهترین مقادیر خطای آموزش و سایر معیارهای ارزیابی برای شبکه EN در شرایط مقادیر مختلف تعداد لایه‌ها و توابع آستانه


چرخه آموزش	$SD_{EMA}$ t) L (a/b)	$E_{MA}$ t) L (a/b)	$R^2$ t) L (a/b)	$E_{MS}$	تعداد لایه‌ها و نرون‌ها	تابع فعال‌سازی
۲۶	۲/۲۶	۱/۶۵	۰/۹۹۱۵	۰/۰۰۰۴۷	۳-۶-۳	LOGSIG
	۰/۳۳	۰/۳۹	۰/۹۷۲۹			
	۰/۰۲۰	۰/۰۲۶	۰/۹۹۳۴			
۴۳	۲/۰۱	۱/۹۳	۰/۹۸۸۰	۰/۰۰۰۴۷	۳-۴-۴-۳	LOGSIG
	۰/۴۱	۰/۴۱	۰/۹۷۴۰			
	۰/۰۳۶	۰/۰۴۲	۰/۹۸۰۳			
۱۶	۲/۱۸	۲/۵۸	۰/۹۸۸۲	۰/۰۰۰۵۹	۳-۶-۳	TANSIG
	۰/۲۶	۰/۵۸	۰/۹۸۱۴			
	۰/۰۶۱	۰/۰۴۳	۰/۹۷۰۱			
۴۸	۲/۴۶	۲/۵۵	۰/۹۹۳۳	۰/۰۰۰۵۳	۳-۴-۴-۳	TANSIG
	۰/۴۳	۰/۴۹	۰/۹۸۲۹			
	۰/۰۴۷	۰/۰۴۱	۰/۹۶۸۶			

جدول ۴: مقادیر واقعی، پیش‌بینی شده و خطای واقعی برای سه پارامتر t, L و a/b


خطا	مقادیر ورودی			مقادیر خروجی			خطا	
	a/b	L	t	a/b	L	t		
۰/۰۳	۰/۹۵	۱/۵۵	۰/۷۱	۱۷/۷	۳۴/۵	۰/۶۸	۱۸/۷	۳۶
۰/۰۵	۰/۹۳	۳/۹۲	۰/۷۴	۱۷/۶	۳۴/۹	۰/۶۹	۱۸/۵	۳۱
۰/۲۱	۰/۳۷	۶/۹۹	۱/۶۸	۱۵/۳	۸۷	۱/۸۹	۱۴/۹	۹۴
۰/۰۵	۱/۴۰	۱/۸۹	۰/۹۴	۱۸/۹	۴۰/۱	۰/۸۹	۱۷/۵	۴۲
۰/۰۴	۰/۴۲	۰/۰۷	۰/۶۵	۲۰/۴	۲۱/۹	۰/۶۱	۲۰/۸	۲۲
۰/۰۷	۰/۰۸	۰/۸۳	۰/۶۳	۲۳/۳	۱۵/۸	۰/۷	۲۳/۲	۱۵
۰/۰۶	۰/۰۹	۳/۲۸	۰/۹۶	۱۶/۷	۴۴/۷	۰/۹	۱۶/۶	۴۸
۰/۰۱	۰/۰۰	۰/۲۱	۰/۶۴	۱۹/۱	۲۳/۲	۰/۶۳	۱۹/۱	۲۳
۰/۰۳	۰/۴۶	۰/۵۴	۰/۶۱	۲۳/۷	۱۴/۵	۰/۶۴	۲۴/۲	۱۴
۰/۰۷	۱/۲۶	۰/۶۶	۰/۶۱	۲۱/۷	۱۵/۷	۰/۵۴	۲۳	۱۵
۰/۰۱	۰/۴۳	۴/۶۴	۱/۳۹	۱۵/۶	۸۰/۶	۱/۴	۱۵/۲	۷۶

جدول ۵: نتیجه حاصل از اعمال خطا بر شبکه‌ی بهینه (الگوریتم یادگیری LM، تابع آستانه‌ی LOGSIG در شبکه‌ی EN با توپولوژی ۳-۶-۳)


چرخه آموزش	$SD_{EMA}$ t) L (a/b)	$E_{MA}$ t) L (a/b)	$R^2$ t) L (a/b)	$E_{MS}$
	۲/۲۳	۲/۲۳	۰/۹۸۵۳	
۲۳	۰/۴۸	۰/۵۸	۰/۹۴۲۴	۰/۰۰۰۴۹
	۰/۰۵۵	۰/۰۵۷	۰/۹۶۵۳	




شکل ۱: نمای کلی خشک کن مورد استفاده: ۱- دریچه هوای ورودی ۲- دمنده ۳- دریچه کنترل سرعت هوا ۴- ترموستات ۵- هیتر ۶- خطی کننده جریان هوا ۷- سینی محصول ۸- ترازو ۹- دریچه خروجی هوا ۱۰- رایانه.



شکل ۲: منحنی نسبت تغییرات رطوبتی با زمان در سرعت ۱ متر بر ثانیه در دماهای مختلف با تیمار آماده سازی ۲/۵٪ کرینات پتاسیم + ۱٪ روغن سبزه



شکل ۳: توپولوژی شبکه عصبی مورد استفاده. P, V, T به ترتیب دما و سرعت هوای گرم و نوع آماده‌سازی اولیه  $t, L, a/b$  به ترتیب زمان خشک شدن انگور، شاخص روشنایی و شاخص نسبت قرمزی به زردی.



شکل ۴: چگونگی فرایند یادگیری شبکه‌ی بهینه

## منابع

- خوش تقاضا، م. ه.، امیری چایجان، ر.، منتظر، غ. و مینایی، س. ۱۳۸۶. پیش بینی ضریب تبدیل شلتوک به برنج سفید در خشک کردن به روش بستر ثابت به کمک شبکه های عصبی مصنوعی. مجله تحقیقات مهندسی کشاورزی، ج ۸، ش ۲: ۱۳۵-۱۵۶.
- نادی، ف. ۱۳۸۴. طراحی، ساخت و ارزیابی خشک کن خورشیدی فعال غیرمستقیم انگور. پایان نامه کارشناسی ارشد مکانیک ماشین های کشاورزی. دانشکده کشاورزی. دانشگاه تربیت مدرس.
- زمردی، ش. و دولتی بانه، ح. ۱۳۸۲. توصیه های لازم برای افزایش کیفیت کشمش. چکیده مقالات اولین همایش ملی خشکبار ایران. تبریز.
- ضرابی، م. ۱۳۷۷. تعیین پارامترهای طراحی در خشک کردن انگور. پایان نامه کارشناسی ارشد شیمی. دانشکده فنی مهندسی. دانشگاه تربیت مدرس.
- AOAC. 1990. Association of Official Analytical Chemists (Report No. 934.06). Arlington, VA.
- Aguilera, J. M., Oppermann, K. and Sanchez, F. 1987. Kinetics of browning sultana grape. Journal of Food Science. 52(4): 993-1025.
- Bishop, C. M. 1994. Neural network and their application. Reviews on scientific Instrumentation. 65, 1803-1832.
- Cybenko, G. 1989. Approximations by superim portions of a sigmoid function. Mathematical Signal Systems. 2: 303-314.
- Doymaz, I. and Mehmet, P. 2002. The effects of dipping pretreatments on air-drying rates of the seedless grapes. Journal of Food Engineering. 52: 413-417.
- Demuth, H. and Beale, M. 2003. Neural Network Toolbox for Matlab-Users Guide Version 4.1. The Mathworks Inc. Natick. U.S.A.
- Elman, J.L. 1990. Finding structure in time. Cognitive Science, 14:179-211.
- Heristev, R. M. 1998. The ANN Book. GNU Public License. Available on (<ftp://ftp.funet.fi/pub/sci/neural/books/>).
- Hornik, K., Stinchcombe, M. and White, H. 1989. Universal approximation of an unknown mapping and its derivatives using multilayer feed forward networks. Neural Networks. 3:551-560.
- Karathanos, V. T. and Belessiotis V. G. 1997. Sun and artificial air drying kinetics of some agricultural products. Journal of Food Engineering. 31: 35-46.
- Pangavhane, D. R. Sawhney, R. L. and Sarsavadia, M. 2000. Drying kinetics studies on single layer Thompson seedless grape under controlled heated air conditions. Journal of Food Processing and Preservation. 24: 335-352.
- Sablani, S. S. and Rahman, M. S. 2003. Using neural networks to predict thermal conductivity of food as a function of moisture content, temperature and apparent porosity. Food Research International. 36: 617-623.
- Togrul, I. T. and Pehlivan, D. 2004. Modeling of thin layer drying kinetics of some fruits under open-air sun drying process. Journal of Food Engineering. 65: 413-425.
- Tulasidas, T. N. Raghavan G. S. V. and Norris, E. R. 1996. Effects of dipping and washing pre-treatment on microwave drying of grape. Journal of Food Process Engineering. 19: 15-24.
- Riva, M. Peri, C. and Lovino, R. 1986. Effects of pretreatment on kinetics of grapes drying. Journal of Food Engineering. 4: 45-52.
- Zhang, Q., Yang, S. X., Mittal, G. S. and Yi, S. 2002. Prediction of performance indices and optimal parameters of rough rice drying using neural network. Biosystems Engineering. 83(3): 281-290.

## Investigation on Important Drying Indices of Grape in Hot Air Flow by Using Artificial Neural Networks

Behroozi Khazaei<sup>1</sup>, N., Amiri Chayjan<sup>2</sup>, R., Tavakoli Hashjin<sup>3</sup>, T. and Khoshtaghaza<sup>3</sup>, M. H.

### Abstract

In this research, prediction of drying time and quality parameters of final production (raisin) in drying process of grape carried out using Artificial Neural Networks (ANNs). Input air temperature, input air velocity and pretreatment type of grape are important parameters in grape drying by hot air flow and were selected as independent variables for ANNs. For creating of training and testing patterns, drying experiments were carried out by a laboratory dryer. Drying time and final product quality at the end of each experiment were obtained and considered as output of ANNs. Several networks as well as Levenberg-Marquardt (LM) training algorithm used for training of patterns. Results showed that the Elman network with topology of 3-6-3 and threshold function of logarithm sigmoid is able to predict the drying time and quality indices (lightness and redness to yellowness) by  $R^2=0.9915$ ,  $0.9729$  and  $0.9934$  and absolute error of  $1.65$ ,  $0.39$  and  $0.026$ , respectively. Noise application to input parameter of training patterns showed that the optimum selected network performance is acceptable, because of producing low training error.

**Key Words:** Grape, Intelligent Prediction, Elman Network, Drying Time, ANN

---

1. PhD Student of Mechanics of Agricultural Machinery, Tarbiat Modares University, Tehran

2. Assistant Professor, Agricultural Engineering Department, Faculty Of AgriculTur, Bu Ali Sina University, Hamedan

3. Professor and Associated Professor, respectively, Agricultural Machinery, Tarbiat Modares University, Tehran