



ششمین کنگره ملی مهندسی ماشین‌های کشاورزی و مکانیزاسیون

پردیس کشاورزی و منابع طبیعی دانشگاه تهران (کرج)

۲۴ و ۲۵ شهریور ۱۳۸۹



مدلسازی سینتیک خشک شدن لایه نازک میوه زرشک (*Berberis Vulgaris*) به کمک شبکه عصبی

مصنوعی

شیوا گرجیان^۱، تیمور توکلی هاشجین^۲، محمدهادی خوش تقاضا^۳

۱، ۲ و ۳- به ترتیب کارشناس ارشد مکانیک ماشین‌های کشاورزی (دانشجوی دکتری)- عضو هیات علمی گروه

مکانیک ماشین‌های کشاورزی- عضو هیات علمی گروه مکانیک ماشین‌های کشاورزی، دانشگاه تربیت مدرس

M88_gorjian@rocketmail.com

چکیده

در تحقیق حاضر، عملکرد یک شبکه پسانتشار خطا (BP)، جهت تخمین میزان رطوبت میوه زرشک (*Berberis Vulgaris*) در طول فرآیند خشک شدن مورد بررسی قرار گرفت. عوامل موثر بر فرآیند خشک شدن نظیر پیش تیمار (شوک حرارتی و امولسیون ۶٪ کربنات پتاسیم + ۳٪ روغن زیتون" و نمونه بدون پیش تیمار)، دمای هوای ورودی به خشک‌کن ($T_1=60$ ، $T_2=70$ و $T_3=80$ درجه سلسیوس)، سرعت هوای ورودی به خشک‌کن ($V_1=0/3$ ، $V_2=1$ و $V_3=1$ متر بر ثانیه) و زمان به عنوان ورودی و میزان رطوبت به عنوان خروجی شبکه عصبی در نظر گرفته شدند. چندین پارامتر موثر بر عملکرد شبکه نظیر نوع الگوریتم یادگیری، نرخ یادگیری، ضریب مومنتم، تعداد لایه‌های پنهان، تعداد نورون‌ها در هر لایه پنهان و نوع تابع فعالسازی جهت بهبود عملکرد شبکه مورد بررسی قرار گرفتند. بهترین الگوریتم یادگیری لونیبرگ-مارکوارت با کمترین مقدار خطا (MSE) انتخاب شد. توپولوژی‌های بهینه ۱-۲۰-۲۰-۱ و ۱-۲۵-۵-۱ با تابع آستانه Logsig و مقادیر خطای ۰/۰۰۳۱۸ و ۰/۰۰۱ و توپولوژی‌های ۱-۲۰-۱ و ۱-۱۵-۱-۱۵ با تابع آستانه Tansig و مقادیر خطای ۰/۰۰۲۹۳ و ۰/۰۰۱۳۰ به دست آمدند.

واژه‌های کلیدی: لایه نازک، شبکه عصبی مصنوعی، الگوریتم یادگیری، میزان رطوبت

میوه زرشک (*Berberis Vulgaris*) به عنوان گیاه دارویی در جهان شناخته شده است. عصاره میوه زرشک صفرابر، تصفیه کننده خون، خوشبو کننده دهان، متعادل کننده اعمال روده، ضد نفرس و مسهل، مسکن حرارت معده، تنظیم کننده ترشح صفرا، کاهش دهنده فشارخون، ضد التهاب و اسپاسم و نشاط آور است. میوه زرشک دارای حدود ۴ درصد مواد قندی، ۶۵ درصد اسید مالیک و اسید تارتاریک و مقداری صمغ می باشد (۳). زرشک تازه به رنگ قرمز روشن، گوشتی، بیضوی شکل و دارای طعمی ترش است. پوست میوه زرشک خشن و مومی^۱ است، لذا باید قبل از خشک کردن این پوست شکاف داده شود. پیش تیمارهایی^۲ نظیر غوطه‌وری در محلول‌های شیمیایی، تیمارهای حرارتی و روش‌های مکانیکی نرخ از دست دادن رطوبت در میوه‌های با پوست مومی را افزایش می‌دهند تا رطوبت به راحتی به سطح آمده و از آن خارج شود (۱۲). در حال حاضر زرشک به شیوه‌های کاملاً سنتی و بدون پیش تیمار خشک می‌گردد. مهم‌ترین مشکل این روش افزایش هزینه و کندی فرآیند خشک شدن است که افزایش خطر صدمه به محصول در اثر باران‌های پاییزه و آلودگی به انواع کپک، مخمر و اتلاف حدود ۳۰ تا ۳۵ درصدی محصول سالیانه را در پی دارد (۴). آگاهی از رفتار خشک شدن در طراحی، شبیه‌سازی، و بهینه‌سازی فرآیند خشک شدن مهم است (۱۹). در حین فرآیند باید کنترل‌های دقیقی به منظور جلوگیری از ضایعات حرارتی اعمال گردد (۶). اساس روش‌های هوشمند، استفاده از دانش نهفته در داده‌های آزمایش، تلاش برای استخراج روابط ذاتی بین آنها و تعمیم آن در موقعیت‌های دیگر است. شبکه‌های عصبی مصنوعی یکی از مهمترین روش‌های هوش مصنوعی بوده که در آن با الهام از مدل مغز انسان، ضمن اجرای فرآیند آموزش، اطلاعات مربوط به داده‌ها، در قالب وزن‌های شبکه ذخیره می‌شوند (۷). مدل‌های شبکه عصبی مصنوعی^۳ (ANN) به طور موفقیت‌آمیزی در تخمین مسائل در فرآیندهای طبیعی عمل کرده‌اند. روش شبکه‌های عصبی نسبت به بسیاری از روش‌های معمولی آماری و قطعی مزایا دارد. در مقایسه با مدل‌های رگرسیون خطی، این روش مقادیر پیش‌بینی را ملزم به قرارگیری در اطراف مقدار میانگین نکرده و به همین دلیل تغییر پذیری واقعی داده را حفظ می‌کند (۵). شبکه عصبی مصنوعی (ANN) سیستم عظیم پردازش اطلاعات با توزیع موازی است که مشخصه‌های عملکردی معینی مشابه شبکه عصبی بیولوژیکی مغز انسان دارد (۱۸). انواع مشهوری از شبکه‌های عصبی نظیر پرسپترون چند لایه^۴ (MLP)، تابع پایه‌ای شعاعی^۵ (RBF) و شبکه‌های عصبی بازگشت کننده^۶ (RNN) وجود دارند. اما همه آن‌ها شامل چند جزء اساسی هستند: گره‌ها، لایه‌ها و اتصالات (۱۴). هر گره سیگنالی را از یک اتصال دریافت می‌کند و سپس سیگنال‌ها قبل از عمل کردن با هم جمع می‌شوند و جهت ایجاد خروجی به تابع انتقال می‌روند. در مرحله بعد سیگنال‌های خروجی به دیگر گره‌ها انتشار پیدا می‌کنند تا به خروجی شبکه دست پیدا کنند. همچنین آن‌ها توانایی پذیرفتن تنظیمات جدید آزمایش را دارند و شبکه می‌تواند برای محدوده وسیعی از خروجی‌ها آموزش داده شود (۲). فارکاس^۷ و همکاران (۹) از شبکه عصبی برای یک خشک‌کن بستر ثابت استفاده کردند. هدف از این تحقیق، استفاده از یک مدل شبکه عصبی مصنوعی برای تعیین

¹ - Waxy

² - Pretreatment

³ - Artificial Neural Network

⁴ - Multi Layer Perceptron

⁵ - Radial Basis Function

⁶ - Recurrent neural network

⁷ - Farkas

رابطه بین توزیع رطوبت در مواد خشک‌کردنی بود. پارامترهای فیزیکی اندازه‌گیری عبارت بودند از دمای هوای خشک‌کن، رطوبت نسبی و بده هوا. نتایج بدست آمده نشان دهنده آن بود که از شبکه عصبی مصنوعی می‌توان برای مدلسازی فرآیند خشک کردن استفاده کرد. طی پژوهشی دیگر فارکاس و همکاران (۱۰) دقت مدل‌های مختلفی از شبکه‌های عصبی مصنوعی را برای پیش‌بینی توزیع رطوبت در خشک‌کن‌های بستر ثابت کشاورزی مورد بررسی قرار دادند. متغیرهای ورودی عبارت بودند از دمای هوای ورودی و خروجی، رطوبت مطلق هوا و بده هوا. نتایج بدست آمده حاکی از آن بود که یک مدل بازخوردی در متغیرهای ورودی می‌تواند برای تخمین مناسب رطوبت در خشک‌کن‌های بستر ثابت به کار رود. همچنین افزایش تعداد متغیرهای ورودی، افزایش معنی‌داری روی دقت مدل نداشت. سبلانی^۱ و رحمان^۲ (۲۰۰۳) از شبکه عصبی مصنوعی برای پیش‌بینی قابلیت هدایت حرارتی مواد غذایی به عنوان تابعی از محتوای رطوبتی، دما و تخلخل ظاهری استفاده کردند. شبکه بدست آمده قادر بود قابلیت هدایت حرارتی را با دقت میانگین خطای نسبی ۱۲/۶٪ و میانگین خطای مطلق ۰/۰۸۱ پیش‌بینی کند. بررسی سینتیک خشک شدن این محصول و مدلسازی روند خشک شدن آن تحت شرایط مختلف جهت آگاهی از رفتار این محصول به منظور طراحی خشک‌کن مناسب ضروری به نظر می‌رسد. در این تحقیق سعی شده است تا با بررسی سینتیک خشک شدن این محصول تحت بازه‌های مختلف دمایی و سطوح مختلف سرعت هوا و همچنین تحت اعمال پیش‌تیمارهای مختلف نتایج دقیق‌تر و کامل‌تری به دست آید. میوه زرشک برای خشک‌شدن نیاز به شرایط ویژه‌ای دارد و رسیدن به یک رطوبت نهایی یکنواخت در محصول یکی از پارامترهای مهم در فرآیند خشک کردن این محصول است. انجام همزمان تخمین و کنترل خشک کردن، نیازمند حل معادلات دیفرانسیل تخمین رطوبت و دمای محصول است. فرآیند خشک کردن زرشک شامل انتقال همزمان جرم و حرارت است. این پدیده در سطوح مختلف قابل مدلسازی ریاضی است. مدل‌های موجود قابلیت ایجاد کنترل مناسب در فرآیند خشک‌کردن در کاربردهای صنعتی را ندارند. با این وجود، کاربرد شبکه‌های عصبی مصنوعی این امکان را فراهم می‌آورد که ابزاری قدرتمند جهت تامین اهداف بالا در دسترس باشد. اهداف انجام این پژوهش عبارتند از؛ استفاده از الگوریتم‌های یادگیری مختلف در آموزش شبکه و بررسی عملکرد آن، تغییر مقادیر آهنگ یادگیری و ضریب اندازه حرکت و بررسی اثر آن بر عملکرد شبکه، تغییر تعداد لایه‌های پنهان و تعداد نرون‌ها در هر لایه و بررسی تاثیر آن بر عملکرد شبکه، بررسی اثر دو تابع آستانه مختلف بر عملکرد شبکه و انجام عملیات پس‌پردازش.

مواد و روش‌ها

زرشک‌های تازه و رسیده از نوع پفکی و بدون هسته از یک مغازه محلی در استان خراسان جنوبی تهیه شدند. نمونه‌ها به منظور کاهش اثرات فعالیت‌های میکروبی تا قبل از شروع آزمایش در دمای ۴°C در یخچال نگهداری شدند. محتوای رطوبت اولیه با استفاده از روش آون داغ به روش وزنی تعیین گردید. بدین منظور نمونه‌های ۲۰ گرمی در دمای 2 ± 105 درجه سلسیوس به مدت ۴ ساعت (تا زمانی که تغییرات بین دو مرحله متوالی توزین

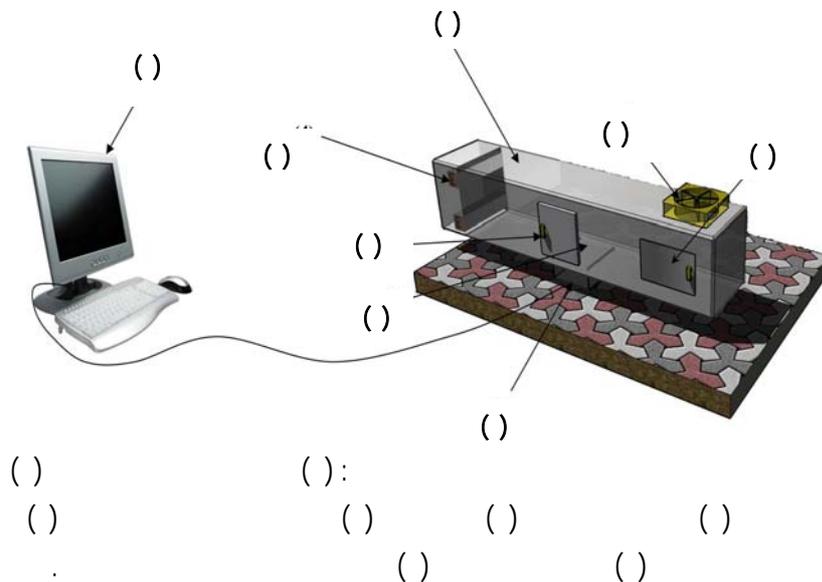
^۱ - Sablani

^۲ - Rahman

نمونه‌ها بسیار کم و ناچیز شود) درون آون قرار گرفته و رطوبت اولیه میوه زرشک ۷۳/۴۴٪ بر پایه تر تعیین شد (۱). با توجه به اینکه پوسته زرشک مومی است به منظور تسهیل در خروج آب از داخل و روی پوسته از پیش تیمار استفاده شد. شوک حرارتی به عنوان پیش تیمار اول (P₁)؛ فرو بردن زرشک‌ها در آب با دمای ۸۵ °C به مدت ۶۰ ثانیه و سپس فرو بردن در داخل آب سرد با دمای ۱۰°C، پیش تیمار دوم (P₂)؛ فرو بردن زرشک‌ها در امولسیون تهیه شده از ۳٪ روغن زیتون و ۶٪ کربنات پتاسیم با دمای ۵۰°C به مدت ۲ دقیقه (۱۵)، و نمونه‌های شاهد که در آن‌ها از پیش تیمار استفاده نشد (P₀). سپس در داخل آب سرد با دمای به مدت زمانی برابر با مدت زمان غوطه‌وری در آب داغ (۶۰ ثانیه) فرو برده شدند (۲۰). استفاده شد. به منظور اطمینان از قابلیت بالای انبار کردن زرشک پس از خشک شدن، زرشک‌ها تا تامین محتوای رطوبت ۱۸٪ بر پایه تر در داخل خشک‌کن قرار داده شدند (۶). در این تحقیق از خشک‌کن لایه نازک در مقیاس آزمایشگاهی، ساخته شده در دانشکده کشاورزی دانشگاه تربیت مدرس، استفاده شد (شکل ۱). این سیستم دارای پورت اتصال به کامپیوتر بود که می‌توانست وزن محصول را در فواصل زمانی قابل تنظیم از طریق برنامه کامپیوتری نمایش دهد و به‌طور پیوسته اندازه‌گیری کند. مقدار نسبت رطوبت^۱ (MR) در هر نقطه زمانی به منظور تهیه نمودارهای خشک‌کردن با استفاده از معادله زیر محاسبه شد (۶):

$$MR = \frac{x - x_e}{x_o - x_e} \quad ()$$

در این معادله x و x_e به ترتیب محتوای رطوبت در زمان t و میزان رطوبت تعادلی^۲ می‌باشند.



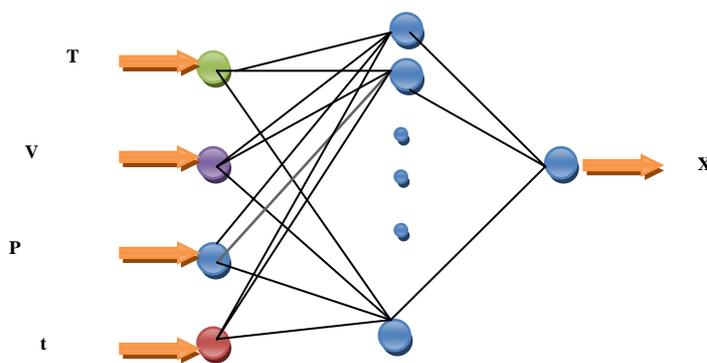
تنظیمات شبکه عصبی مصنوعی

¹ -Moisture ratio

² - Equilibrium moisture content

شبکه مورد استفاده، شبکه پرسپترون چندلایه بود. در این تحقیق ساختاری برای پیش‌بینی تغییرات میزان رطوبت تحت هر شرایط آزمایش در نظر گرفته شد. بنابراین خروجی شبکه میزان رطوبت زرشک است. تعداد نرون‌های ورودی شبکه برابر تعداد متغیرها در ورودی (نوع پیش‌تیمار، دمای هوا، سرعت هوا و زمان) است و تعداد لایه‌های میانی و نرون‌های لایه میانی بایستی به تعدادی انتخاب شود که مقدار خطای خروجی شبکه کمترین مقدار باشد، به عبارتی شبکه بهینه حاصل شود (شکل ۲). با داشتن جرم ماده خشک محصول و جرم محصول در هر فاصله زمانی که اندازه‌گیری شده است، میزان رطوبت محصول در هر فاصله زمانی از رابطه (۱) قابل محاسبه است.

$$X_i = \frac{m_i - m_d}{m_i} \times 100 \quad (1)$$



در این معادله X_i میزان رطوبت بر پایه تر در فاصله زمانی i ، m_i مقدار جرم محصول در فاصله زمانی i و m_d وزن خشک محصول که بر حسب کیلوگرم می‌باشد. به منظور بررسی و ارزیابی شبکه‌های مختلف، پایگاه داده‌ای به سه قسمت تقسیم شد: آموزش^۱، آزمون^۲ و اعتبارسنجی^۳. برای پیدا کردن بهترین پیش‌بینی‌ها، شبکه‌های مختلفی بر داده‌های مذکور اعمال شدند. برای طراحی و آزمون شبکه عصبی مصنوعی از برنامه‌نویسی در *M.file* نرم افزار *Matlab R2009a* استفاده شد. پارامترهای ترکیبی مانند نوع الگوریتم یادگیری، تعداد لایه‌های پنهان، تعداد نرون‌ها در لایه پنهان، تعداد چرخه آموزش^۴، ضریب یادگیری^۵ و اندازه حرکت^۶ در طی فرآیند آموزش شبکه عصبی و به روش

¹ -Train

² - Test

³ - Evaluation

⁴ - Epoch

⁵ - Learning coefficient

⁶ - Momentum

آزمون و خطا تعیین شد. بررسی قابلیت تعمیم شبکه عصبی آموزش دیده، گام آخر در توسعه مدل شبکه عصبی مصنوعی است. در این مرحله مدل‌های شبکه عصبی آموزش دیده به وسیله مجموعه داده‌های آزمون که مستقل از داده‌های آموزش است مورد بررسی قرار گرفت. برای یافتن شبکه با معماری مناسب به کمک الگوریتم‌های آموزشی، از معیار خطای مربعات میانگین^۱ و خطای مطلق میانگین^۲ استفاده شد.

$$MSE = \frac{\sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2}{n_p \times n_0} \quad ()$$

$$MAE = \frac{1}{n} \sum_{i=1}^N |S_{ip} - T_{ip}| \quad ()$$

در این معادله MSE و MAE به ترتیب میانگین مربعات خطا و میانگین خطای مطلق در مرحله آموزش، S_{ip} خروجی شبکه در نرون i و الگوی p خروجی هدف در نرون i و الگوی p ، T_{ip} تعداد نرون‌های لایه خروجی، N تعداد نرون‌های خروجی و m تعداد الگوهای آموزشی است. در واقع همان‌گونه که یک سلول بیولوژیک باید به سطح آستانه تحریک خاصی برسد تا یک سیگنال تولید کند، توابع آستانه نیز تا زمانی که ورودی‌های ترکیب شده و وزن-دار شده به یک حد آستانه‌ای خاص نرسند مقدار خروجی نظیر بسیار کوچکی تولید می‌کنند. و زمانی که به حد آستانه‌ای خاصی برسند، سلول عصبی تحریک شده و سیگنال خروجی تولید می‌کند. توابع آستانه^۳ مختلفی برای یافتن حالت بهینه شبکه‌ها مورد ارزیابی قرار گرفت که عبارتند از:

$$Y_i = \frac{1}{1 + \exp(X_i)} \quad (۴) \text{ تابع سیگموئیدی لگاریتمی}^۴$$

$$(۵) \text{ تابع خطی}^۵$$

$$Y_j = X_j$$

$$Y_i = \frac{2}{(1 + \exp(-2X_j)) - 1} \quad (۶) \text{ تابع تانژانت سیگموئیدی}^۶$$

برای شبکه MLP ، m تعداد نرون‌های لایه خارجی، w_{ij} وزن بین لایه i و j ، y_i خروجی نرون i ام و b_j مقدار بایاس نرون لایه j ام است. x_j مجموع ورودی‌های وزن دار هر نرون لایه j است و از رابطه زیر محاسبه می‌شود:

^۱ - Mean square error
^۲ - Mean absolute error
^۳ - Activation Function
^۴ - Logsig
^۵ - Purelin
^۶ - Tansig

$$X_j = \sum_{i=1}^m W_{ij} Y_i + b_j \quad (7)$$

در ساختار شبکه عصبی مورد استفاده برای مساله حاضر از تابع خطی در لایه خروجی و از تابع سیگموئیدی لگاریتمی و تانژانت سیگموئیدی در لایه پنهان استفاده شد. یکی از الگوریتم‌های بهنگام‌سازی شبکه پرسپترون چندلایه، الگوریتم پس‌انتشار خطا است. این الگوریتم روشی منظم برای آموزش شبکه‌های عصبی چندلایه است. شبکه‌های پس‌انتشار به کمک روش یادگیری باسرپرست آموزش داده می‌شود. هدف این تحقیق، آموزش شبکه‌ها برای دستیابی به تعادل بین توانایی یادگیری الگوهای آموزش و توانایی ایجاد پاسخ مناسب برای الگوهای ناشناخته است. ضرایب آهنگ یادگیری ($\eta > 0$) و ضریب اندازه حرکت ($\alpha < 1$)، در فرایند تغییر وزن شبکه تأثیر قابل توجهی دارند. مقدار کوچک آهنگ یادگیری باعث افزایش زمان یادگیری شده، اما با تعداد تکرارهای کافی، می‌توان به شبکه آموزش دیده مناسب دست یافت. مقادیر بزرگ آهنگ یادگیری سبب افزایش سرعت یادگیری شده، ولی پس از مدتی که وزن‌ها تا حدودی به مقدار بهینه نزدیک شد، مقدار بزرگ آن باعث می‌شود که دستیابی به نقطه بهینه جامع^۱ مشکل و حتی غیرممکن شود بنابراین برای پیدا کردن مقدار بهینه آن از روش آزمون و خطا استفاده می‌شود. ضریب اندازه حرکت در الگوریتم یادگیری پس انتشار برای رهایی از گرفتار شدن در کمینه‌های محلی پیش‌بینی شده است، که با وارد کردن ضربه‌ای ناگهانی به سیستم، آن را از حالت یادگیری کاذب خارج می‌کند.

نتایج و بحث

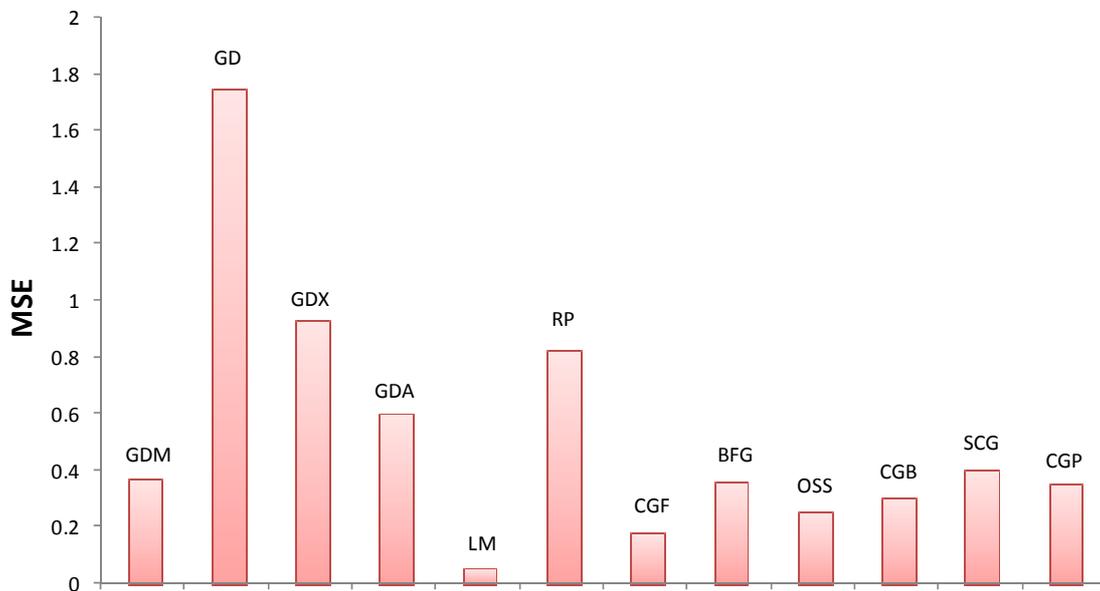
تعیین اینکه کدام الگوریتم برای یک مساله خاص سریع‌تر عمل می‌کند کار بسیار دشواری است. زیرا این مساله به فاکتورهای زیادی بستگی دارد از جمله پیچیدگی مساله، تعداد داده‌های مجموعه آموزشی، تعداد وزن‌ها و بایاس-ها در شبکه، مقدار خطای هدف و.... برخی از الگوریتم‌ها برای مسائل تخمینی بهتر از سایرین عمل می‌کنند. برخی برای طبقه‌بندی مناسب‌ترند. به منظور تعیین بهترین نوع الگوریتم برای مساله حاضر، شبکه با الگوریتم‌های مختلف با تعداد چرخه آموزشی ۱۰ و تابع آستانه *Tansig* و یک لایه پنهان و تعداد ۲۰ نرون در این لایه آموزش داده شد و عملکرد شبکه بررسی شد (جدول ۱). مساله‌ای که در الگوریتم‌های آموزشی مطرح است، سرعت همگرایی است. چون در این مساله با توجه به ابعاد متوسط آن همگرایی سریع انجام می‌شود، لذا تفاوت بین الگوریتم‌ها از لحاظ سرعت قابل بررسی نبود. هرچند الگوریتم *LM* نسبت به بقیه الگوریتم‌ها دارای سرعت بیشتر و در مقابل حجم محاسباتی بالاتر است. به طور کلی الگوریتم *LM* برای مسائل تخمینی خوب عمل می‌کند. بعد از آن الگوریتم‌های *CGF* و *OSS* هم عملکرد خوبی دارند. به منظور مقایسه بهتر، عملکرد شبکه با الگوریتم‌های ذکر شده در شکل (۳) نشان داده شده است.

جدول ۱- بررسی نوع الگوریتم آموزشی بر عملکرد شبکه

Epochs	MSE	نوع الگوریتم یادگیری
۱۰	۱/۷۵	GD

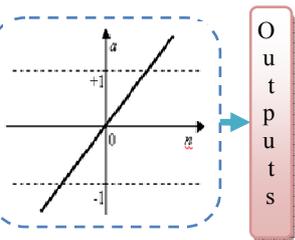
^۱ - Global Minimum

"	۰/۳۶۹	GDM
"	۰/۹۲۸	GDX
"	۰/۶۰۳	GDA
"	۰/۰۵۷۱	LM
"	۰/۸۲۴	RP
"	۰/۱۸۱	CGF
"	۰/۳۵۷	BFG
"	۰/۲۴۹	OSS
"	۰/۳۰۳	CGB
"	۰/۳۹۷	SCG
"	۰/۳۵۳	CGP



شکل ۳- عملکرد شبکه با الگوریتم‌های مختلف

الگوریتم *GDM* به دلیل اضافه شدن مومنتم دارای عملکرد بهتری نسبت به *GD* می‌باشد. الگوریتم *CGF* کمی بیشتر از الگوریتم‌های ساده حافظه می‌برند. لذا برای شبکه‌های با تعداد وزن زیاد و حجم بالا مناسبند. الگوریتم *RP* برای مسائل تشخیص الگو مناسب است و برای تخمین خوب عمل نمی‌کند. الگوریتم‌های *SCG* برای اغلب مسائل عملکرد خوبی دارند و برای این مساله نیز عملکرد متوسطی داشته است. بنابر این با توجه به جوانب مختلف مساله باید بهترین الگوریتم برای آن مساله خاص انتخاب شود. و به طور کلی نمی‌توان گفت که یک الگوریتم بر دیگری برتری دارد. به منظور بررسی تغییر مقادیر آهنگ یادگیری و ضریب اندازه حرکت بر عملکرد شبکه از یک شبکه سه لایه (ورودی، پنهان و خروجی) برای آموزش استفاده شد. از تابع آستانه *Tansig* در لایه پنهان و تابع آستانه *Purelin* در لایه خروجی استفاده شد (شکل ۴).



شکل ۴- شبکه پرسپترون سه لایه با تابع آستانه *Tansig* در لایه پنهان.

در این بخش هدف بررسی اثر تغییرات آهنگ یادگیری و ضریب اندازه حرکت بر عملکرد شبکه می باشد. با توجه به اینکه دو پارامتر آهنگ یادگیری و ضریب اندازه حرکت در طی فرآیند آموزش با الگوریتم یادگیری *GDM* مقادیری ثابت هستند، لذا از این الگوریتم برای آموزش استفاده شد. تغییرات آهنگ یادگیری در سطوح ۰/۱، ۰/۰۱ و ۰/۰۰۱ و تغییرات ضریب اندازه حرکت در ۰/۰۰۱، ۰/۰۱ و ۰/۰۵ مورد بررسی قرار گرفت. تابع کارایی شبکه روی *MAE* تنظیم شد. تعداد لایه پنهان یک عدد و تعداد نرون‌ها در این لایه به منظور بررسی بهتر تغییرات آهنگ یادگیری و ضریب اندازه حرکت، ۷ عدد در نظر گرفته شد. همانطور که قبلاً گفته شد، ضریب اندازه حرکت به تمامی پارامترهای شبکه اینرسی و یا اندازه حرکت اضافه کرده و تمامی آن‌ها را در مسیری که منجر به کاهش خطا شود پیش می‌برد. و شبکه را از به دام افتادن در کمینه‌های محلی حفظ می‌کند. نتایج نشان می‌دهند که افزایش این پارامتر منجر به کاهش خطای شبکه می‌شود به طوریکه در آهنگ یادگیری ثابت (۰/۰۱) مقادیر خطا با افزایش ضریب اندازه حرکت از ۰/۰۰۱ تا ۰/۰۱ کاهش یافت. اما افزایش این پارامتر به مقدار ۰/۰۵ منجر به واگرایی شبکه شده و خطا افزایش یافت. از طرفی با افزایش آهنگ یادگیری از ۰/۰۱ تا ۰/۲ مقدار خطا کاهش یافت. برای تعیین مقادیر آهنگ یادگیری یا اندازه حرکت هیچگونه استاندارد وجود ندارد و برای هر مسأله‌ای باید این مقادیر از طریق آزمون و خطا تعیین شوند. تعیین مناسب‌ترین مقادیر برای این پارامترها ممکن است مشکل باشد. بهترین روش استفاده از الگوریتمی است که بتوان این مقادیر را، بویژه آهنگ یادگیری را به عنوان پارامتری وابسته به زمان در نظر گرفت. نتایج حاصل از این آموزش در جدول (۲) ثبت شده است. لذا برای این مسأله بهترین مقدار مومنتم ۰/۰۱ و بهترین مقدار آهنگ یادگیری ۰/۱ انتخاب شد.

جدول ۲- تاثیر مقادیر η و α بر میزان خطا

MAE	ضریب اندازه حرکت (α)	آهنگ یادگیری (η)
۰/۸۹۷	۰/۰۰۱	۰/۰۱
۰/۶۸۴	۰/۰۱	۰/۰۱
۰/۸۱۹	۰/۰۵	۰/۰۱

۰/۵۶۶	۰/۰۰۱	۰/۱
۰/۴۸۷	۰/۰۱	۰/۱
۰/۶۲۸	۰/۰۵	۰/۱
۰/۵۰۱	۰/۰۰۱	۰/۲
۰/۴۹۳	۰/۰۱	۰/۲
۰/۵۰۴	۰/۰۵	۰/۲

به منظور تعیین بهترین توپولوژی برای شبکه آزمایش‌های اولیه انجام شد. توپولوژی‌های مختلف تک لایه با تعداد مختلف نرون‌ها و همچنین دو لایه با تعداد مختلف نرون در هر لایه بررسی شد. خطای حاصل از داده‌های آزمون یک شاخص خوب برای تعیین تعداد مناسب لایه‌های میانی و همچنین تعداد نرون‌ها در این لایه‌ها است. شبکه با تعداد ثابت ۲۰ چرخه، آموزش داده شد. به منظور آموزش شبکه از الگوریتم یادگیری *LM* و دو تابع آستانه *Tansig* و *Logsig* در لایه پنهان و تابع *Purelin* در لایه خروجی استفاده شد. نتایج حاصل از آموزش شبکه در جداول (۳) و (۴) آمده است.

جدول ۳- نتایج حاصل از بکارگیری الگوریتم یادگیری *LM*، تابع آستانه *Tansig* در شبکه

تعداد لایه میانی	تعداد نرون لایه میانی اول	تعداد نرون لایه میانی دوم	MSE	چرخه آموزش
۱	۵	-	۰/۰۰۸۳۳	۲۰
۱	۱۰	-	۰/۰۰۵۴۵	"
۱	۱۵	-	۰/۰۰۴۸۶	"
۱	۲۰	-	۰/۰۰۲۹۳	"
۱	۲۵	-	۰/۰۰۳۴۶	"
۲	۵	۵	۰/۰۱۰۵	"
۲	۱۰	۵	۰/۰۰۳۹۵	"
۲	۱۵	۵	۰/۰۰۲۷۳	"
۲	۲۰	۵	۰/۰۰۳۱۳	"
۲	۱۰	۱۰	۰/۰۰۳۱۷	"
۲	۱۵	۱۰	۰/۰۰۱۷۴	"
۲	۱۵	۱۵	۰/۰۰۱۳۰	"
۲	۱۵	۲۰	۰/۰۰۲۴۸	"

جدول ۴- نتایج حاصل از بکارگیری الگوریتم یادگیری *LM*، تابع آستانه *Logsig* در شبکه

تعداد لایه میانی	تعداد نرون لایه میانی اول	تعداد نرون لایه میانی دوم	MSE	چرخه آموزش
۱	۵	-	۰/۰۶۳۸	۲۰
۱	۱۰	-	۰/۰۰۴۹۲	"

"	۰/۰۰۴۲۲	-	۱۵	۱
"	۰/۰۰۳۱۸	-	۲۰	۱
"	۰/۰۰۳۸۵	-	۲۵	۱
"	۰/۰۲۸۵	۵	۵	۱
"	۰/۰۰۴۰۱	۵	۱۰	۱
"	۰/۰۱۰۹	۵	۱۵	۲
"	۰/۰۰۲۴۶	۵	۲۰	۲
"	۰/۰۰۱۷۳	۵	۲۵	۲
"	۰/۰۰۸۷۴	۵	۳۰	۲
"	۰/۰۰۱۰۰	۱۰	۲۵	۲
"	۰/۰۰۱۴۷	۱۵	۲۵	۲

همانطور که نتایج جدول نشان می‌دهند مقدار خطای شبکه در توپولوژی‌های دولایه با تعداد نرون‌هایی برابر با شبکه تک لایه نظیر دارای خطای کمتری هستند. این نوع شبکه‌ها اصطلاحاً به شبکه‌های کم عمق^۱ معروفند. افزایش بیش از حد تعداد نرون‌ها منجر به افزایش حجم محاسبات شده و بر پیچیدگی مساله می‌افزاید. با توجه به نتایج حاصل از شبکه بهترین توپولوژی‌ها برای شبکه با تابع آستانه *Tansig*، ۱-۲۰-۴ و ۱-۱۵-۱۵-۴ می‌باشند و برای تابع آستانه *Logsig* بهترین توپولوژی‌ها ۱-۲۰-۴ و ۱-۲۵-۱۰-۴ می‌باشند.

جدول ۵- نتایج حاصل از تحلیل رگرسیونی توپولوژی‌های مختلف شبکه با تابع آستانه *Tansig*.

توپولوژی	R (آموزش)	R (اعتبارسنجی)	R (آزمون)
۴-۵-۱	۰/۹۸۸	۰/۹۸۸	۰/۹۸۱
۴-۱۰-۱	۰/۹۹۲	۰/۹۸۷	۰/۹۸۸
۴-۱۵-۱	۰/۹۹۳	۰/۹۹۲	۰/۹۹۳
۴-۲۰-۱	۰/۹۹۶	۰/۹۹۴	۰/۹۹۳
۴-۲۵-۱	۰/۹۹۵	۰/۹۹۴	۰/۹۹۱
۴-۵-۵-۱	۰/۹۸۶	۰/۹۸۳	۰/۹۸۱
۴-۱۰-۵-۱	۰/۹۹۴	۰/۹۹۴	۰/۹۹۶
۴-۱۵-۵-۱	۰/۹۹۶	۰/۹۹۵	۰/۹۹۷
۴-۲۰-۵-۱	۰/۹۹۶	۰/۹۹۳	۰/۹۹۰
۴-۱۰-۱۰-۱	۰/۹۹۶	۰/۹۹۱	۰/۹۹۴
۴-۱۰-۱۵-۱	۰/۹۹۷	۰/۹۹۶	۰/۹۹۵
۴-۱۵-۱۵-۱	۰/۹۹۸	۰/۹۹۵	۰/۹۹۶
۴-۲۰-۱۵-۱	۰/۹۹۶	۰/۹۹۴	۰/۹۹۵

^۱ - Shallow Networks

توپولوژی	R (آموزش)	R (اعتبارسنجی)	R (آزمون)
۴-۵-۱	۰/۹۰۷	۰/۸۹۴	۰/۸۷۵
۴-۱۰-۱	۰/۹۹۳	۰/۹۹۳	۰/۹۹۳
۴-۱۵-۱	۰/۹۹۴	۰/۹۹۴	۰/۹۹۰
۴-۲۰-۱	۰/۹۹۵	۰/۹۹۳	۰/۹۹۵
۴-۲۵-۱	۰/۹۹۴	۰/۹۸۹	۰/۹۸۹
۴-۵-۵-۱	۰/۹۵۹	۰/۹۴۸	۰/۹۵۶
۴-۱۰-۵-۱	۰/۹۹۴	۰/۹۹۲	۰/۹۹۲
۴-۱۵-۵-۱	۰/۹۸۵	۰/۹۸۱	۰/۹۸۵
۴-۲۰-۵-۱	۰/۹۹۷	۰/۹۹۷	۰/۹۹۸
۴-۲۵-۵-۱	۰/۹۹۸	۰/۹۹۷	۰/۹۹۷
۴-۳۰-۵-۱	۰/۹۹۸	۰/۹۸۲	۰/۹۸۱
۴-۲۵-۱۰-۱	۰/۹۹۸	۰/۹۹۶	۰/۹۹۸
۴-۲۵-۱۵-۱	۰/۹۹۸	۰/۹۹۷	۰/۹۹۷

کارایی شبکه آموزش دیده تا حدی با استفاده از خطاهای مجموعه‌های آموزشی، اعتبارسنجی و آزمایش قابل اندازه‌گیری می‌باشد. رویه *Postreg* برای انجام این تحلیل‌ها طراحی شده است. اگر خروجی شبکه‌ها و داده‌های هدف با هم برابر باشد مقدار شیب خط برازش داده برابر ۱ خواهد بود. به منظور تحلیل رگرسیونی نتایج حاصل از عملکرد شبکه‌های فوق در یادگیری از رگرسیون خطی و شاخص ضریب همبستگی "*R*" بین مقادیر واقعی و مقادیر تخمین زده شده توسط شبکه برای داده‌های آموزشی، آزمون و اعتبارسنجی استفاده شد. نتایج حاصل از این بررسی برای برای توپولوژی‌های مختلف در جدول (۵) و (۶) نشان داده شده است. از نتایج حاصل در جدول اینگونه برمی‌آید که شبکه‌های بهینه شده که دارای مقدار *MSE* کمتری بودند مقدار ضریب همبستگی بیشتری را هم نشان می‌دهند که نشانگر تخمین خوب شبکه و نزدیک بودن مقادیر خروجی از شبکه به مقادیر واقعی است.

فهرست منابع

- 1- Aghbashlo, M., Kianmehr, M., Arab Husseini, A. 2008. Evaluation of Thin-layer Drying models for describing of drying kinetics of Barberry. Fifth national congress of Engineering of Agricultural Machinery and Mechanization. (In Persian).
- 2- Amiri Chayjan, R., 2006. Intelligent Prediction of drying process of Rice. P.h.d thesis. Department of Mechanic of Agricultural Machinery. Agricultural faculty. Tarbiat Modares University. (In Persian)
- 3- Anonymous 1. Available on www.qayen.com. (In Persian)
- 4- Anonymous 2. Available on www.meymand.com. (In Persian)
- 5-Behroozi Khazae, N. 2007. Quality prediction of Raisin using Artifitial Neural Network. M.sc. thesis. Department of Mechanic of Agricultural Machinery. Agricultural faculty. Tarbiat Modares University. (In Persian)
- 6-Chajii, H., Ghassem Zade, H., Ranjbar, A., 2008. Effect of Ethyl-Oleate oil and Potassium Carbonate powder and warm water on drying kinetics of Barberry. Fifth national congress of Engineering of Agricultural Machinery and Mechanization. (In Persian)
- 7- Dayhoff, J. E. 1990. Neural Network Principles. Prentice-Hall International, U.S.A.
- 8- Demuth, H. and Beale, M. 2003. Neural Network Toolbox for Matlab- Users Guide Version 4.1. Natick: The Mathworks Inc.

- 9- Farkas, I., Reményi, P., and BirÓ, B. 2000a. A neural network topology for modeling grain drying. Computers and Electronics in Agriculture. **26**: 147-158.
- 10- Farkas, I., Reményi, P., and BirÓ, B. 2000b. Modeling aspects of grain drying with a neural network. Computers and Electronics in Agriculture. **29**: 99-113.
- 11- Heristev, R.M. 1998. The ANN Book. GNU Public License. USA.
- 12- Kim, M.H. and R.T, Toledo. 1987. Effect of osmotic dehydration and high temperature fluidized bed drying on properties of dehydrated Rabbiteye blueberries. Food Science **52**(4): 980-984.
- 13- Mola, D., Fallahi, H. 1995. Usage of Fluid beds in drying of Barberry. Engineering faculty. Shiraz university. First seminar of Barberry. (In Persian)
- 14- Movagharnejad, K., Nikzad, and Maryam., 2007. Modeling of tomato drying using artificial neural network. Computers and Electronics in agriculture. **59**: 78-85.
- 15- Pangavhane, D.R., Sawhney, and R.L., Sarsavadia, P.N. 1998. Effect of various dipping pretreatment on drying kinetics of Thompson seedless grapes. Food Engineering., **39**: 211-216.
- 16- Riva, M. and Peri, C. 1986. Kinetics of sun and air drying of different varieties of seedless grapes. Food Technology. **21**: 199-208.
- 17- 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.
- 18- Satish, S and Pydi Setty, Y.P. 2005. Modeling of a continuous fluidized bed dryer using artificial neural networks. Int. Commun. Heat and Mass Transfer **32**: 539–547.
- 19- Senadeera, W., B.R., Young, G., and Wijesinghe, B., 2003. Influence of shapes on drying kinetics during fluidized bed drying. Food Engineering. **58**: 277-283.
- 20- Telis, V., Lourencon, V.A., Gabas, A.L., and Telis-Romero, J. 2006. Drying rates of Rubi grapes submitted to chemical pretreatments for raisin production. Pesq.agropec.bras.,Brasilia., **41**: 503-509.

Modeling of thin-layer drying kinetics of Barberry Fruit (*Berberis Vulgaris*) using Artificial Neural Network

Abstract

In order to investigate the effect of different levels of temperature, velocity and pretreatment on the drying time of thin layer of Barberries (*berberis vulgaris*), an experiment using a factorial experiment conducted carried out based on completely randomized block design with three levels of temperature (T1=60, T2=70 and T3=80 °C) and three levels of velocity (V1=0.3, V2=0.5 and V3=1 m/s) for untreated berries and treated berries with heat shocking and "6% K₂CO₃ + 3% olive oil" emulsion with three replicates. Drying times were affected by temperature and pretreatment at the probability level of 99%. The maximum drying time was recorded 2920 minutes for untreated berries at the temperature and velocity of 60 °C and 0.3 m/s respectively and the minimum drying time was recorded 70 minutes for treated berries with K₂CO₃ and olive oil emulsion. In our study multi layer perceptron (MLP) Neural Network with an adjustment learning algorithm of Levenberg-Marquardt with sigmoid logarithm and sigmoid tangent functions were used. The best topology of MLP with LM learning algorithm and Tansig threshold function can predict the moisture content was 4-30-16-1 with correlation coefficient of 0.9992 and actual error of 0.00025. Besides the best topology of this neural structure with Logsig threshold function can predict the moisture content was 4-25-5-1 with correlation coefficient of 0.9991 and actual error of 0.00032. These results indicate ability of artificial neural network to model and predict drying process.

Keywords: Pretreatment, Completely randomized block , Learning algorithm, Topology.