

پیش بینی مشخصه‌های رطوبت تعادلی آفتابگردان به کمک مدل های تجربی و

شبکه‌های عصبی مصنوعی

رضا امیری چایجان^{۱*} و جعفر امیری پریان^۲

*- نویسنده مسؤول: دانشیار گروه مهندسی بیوسیستم - دانشکده کشاورزی - دانشگاه بوعلی سینا - همدان (amirireza@basu.ac.ir)

۲- استادیار گروه مهندسی بیوسیستم - دانشکده کشاورزی - دانشگاه بوعلی سینا - همدان

تاریخ دریافت: ۹۰/۳/۳۱ تاریخ پذیرش: ۹۱/۸/۱۷

چکیده

در این پژوهش، از مدل های تجربی و شبکه‌های عصبی مصنوعی برای پیش بینی محتوای رطوبت تعادلی بذر و مغز آفتابگردان استفاده شد. چهار مدل ریاضی هندرسون اصلاح شده، چانگ-پی فاست، هالسی و گب برای این منظور بکار رفت. دو نوع شبکه پس انتشار (پیشرو و پیشخور) مورد آزمون قرار گرفت. به منظور آموزش الگوهای ورودی، الگوریتم یادگیری لونیگ-مارکواریت مورد استفاده قرار گرفت. محدوده‌های دما و رطوبت نسبی به ترتیب بین ۲۵ تا ۴۰°C و ۱۱ تا ۹۶٪ اعمال شد. بهترین نتایج برای مدل های تجربی، برای مدل گب و هالسی به دست آمد. بهترین خروجی برای شبکه‌های عصبی مورد استفاده، مربوط به شبکه پیشخور، توپولوژی ۱-۳-۵-۳ و تابع آستانه TANSIG-TANSIG-LOGSIG است. با این شبکه بهینه، ضریب تبیین و خطای نسبی میانگین، به ترتیب ۰/۹۹۳۵ و ۵/۰۱ حاصل شد. این نتایج، برتری شبکه‌های عصبی مصنوعی را نسبت به مدل‌های ریاضی نشان می‌دهد. زیرا علاوه بر ایجاد خطای کمتر در پیش‌بینی مقدار رطوبت تعادلی، قادر است شاخص کیفی را نیز به عنوان ورودی لحاظ کند.

کلید واژه‌ها: آفتابگردان، رطوبت تعادلی، شبکه‌های پس انتشار، فعالیت آبی، مدل های تجربی

مقدمه

از اینرو خشک کردن محصول برداشت شده ضروری است (گوپتا و داس، ۱۹۹۷). داده‌های مربوط به رطوبت نسبی تعادلی (ERH)^۴ و دمای انبار برای پیش‌بینی رطوبت تعادلی دانه و مغز آفتابگردان، طراحی فرآیند پس از برداشت و تنظیم سیستم‌های انبارداری ضروری است. فرآیند خشک کردن آفتابگردان موجب حفظ کیفیت دانه آفتابگردان و محصولات جانبی می‌شود لذا دستیابی به سینتیک دفع^۵ رطوبت محصول به منظور خشک کردن بهینه دانه‌های آفتابگردان ضروری است.

آفتابگردان^۱ یکی از گیاهان روغنی است که روغن آن دارای پایداری و کیفیت بالایی است (مازا و جایاس^۲، ۱۹۹۱). مدیریت فرایند پس از برداشت آفتابگردان بر مبنای مطالعات سنتی و متداول می‌باشد (گوپتا و داس^۳، ۱۹۹۷). در روش های مذکور، به منظور کاهش ضایعات، محصول با رطوبت بالا برداشت می‌شود (حدود ۱۵٪ ماده خشک). ولی رطوبت مذکور مناسب عملیات پس از برداشت و انبارداری نیست.

4- Equilibrium Relative Humidity
5- Dedorption Kinetic

1- Helianthus Annuus
2- Mazza & Jayas
3- Gupta & Das

زیبیسینسکی و همکاران^{۱۰} (۱۹۹۶) برای مدل سازی فرایند تبخیر رطوبت در یک خشک کن بستر سیال از شبکه های عصبی مصنوعی استفاده کردند و زیبیسینسکی و سیسیلسکی (۲۰۰۰) برای پیش بینی ضریب انتقال حرارت مواد مختلف و اسلام و همکاران^{۱۱} (۲۰۰۳) برای پیش بینی نرخ خشک کردن قطعات سیب زمینی از روش شبکه های عصبی کمک گرفتند.

ژانگ و همکاران^{۱۲} (۲۰۰۲) از شبکه های عصبی مصنوعی برای پیش بینی شاخص های خشک کردن شلتوک از پارامترهای موثر در خشک کردن به روش بستر ثابت استفاده کردند و کویلوس و ریز^{۱۳} (۲۰۰۳) برای پیش بینی میزان رطوبت خروجی در فرایند خشک کردن هویج از این روش بهره بردند.

با توجه به ضرورت های بیان شده، اهداف این تحقیق عبارت است از:

- ۱- تعیین مقادیر آزمایشی محتوای رطوبت تعادلی در دما و رطوبت نسبی تعادلی برای بذر و مغز محصول آفتابگردان
- ۲- کاربرد مدل های تجربی برای تخمین مقادیر رطوبت نسبی تعادلی و محتوای رطوبت تعادلی و انتخاب بهترین مدل
- ۳- سرانجام استفاده از شبکه های عصبی مصنوعی برای پیش بینی محتوای رطوبت تعادلی در دما و رطوبت نسبی تعادلی برای بذر و مغز محصول آفتابگردان و مقایسه نتایج آن با نتایج مدل های تجربی.

مواد و روش ها

روش آزمایش

رقم پروگرس^{۱۴} که یک رقم روغنی آفتابگردان است، برای انجام پژوهش ها انتخاب شد. ۱۰ نمونه پنج

محتوای رطوبت تعادلی (EMC)^۱ در هنگام جذب و دفع رطوبت برای محصولات کشاورزی در شرایط دمایی و رطوبت نسبی مشابه، یکسان نیست. این تفاوت، پسماند^۲ نامیده می شود. این پدیده در شناخت زمان و چگونگی تاثیر فرایندهای رطوبت گیری و خشک کردن بر رطوبت تعادلی محصول مؤثر است (بلاهووک و یانیوتیس^۳، ۲۰۰۹).

تفاوت ها در خصوصیات فیزیکی بذرهای پرروغن و معمولی آفتابگردان در تحقیقات قبلی گزارش شده است (سانتالا و ماسکرونی^۴، ۲۰۰۳). گزارش پژوهشگران مختلف نشان می دهد که مدل هندرسون اصلاح شده و چانگ پی-فاست برای غلات با درصد نشاسته زیاد و مواد فیبری مناسب است، در صورتیکه مدل هالسی برای محصولات با پروتئین و روغن زیاد مناسب است (چایجان^۵، ۲۰۱۰؛ ایگلسیاس و شیریف^۶، ۱۹۷۶؛ پنگ و همکاران^۷، ۲۰۰۷؛ سیمال و همکاران^۸، ۲۰۰۷).

در شرایطی که روابط بین پارامترهای مستقل و وابسته پیچیده باشد، روش های مدل سازی ریاضی، محدودیت هایی از قبیل انتخاب پارامترها، اعمال پیش فرض ها برای حل معادلات و پیچیدگی حل معادلات را در پی خواهد داشت. بنابراین بهترین انتخاب، استفاده از روش های بهینه سازی هوشمند است. یکی از این روش ها، شبکه های عصبی مصنوعی^۹ است که یک روش غیرالگوریتمی بوده و اساس آن بر مبنای آموزش و یادگیری به کمک داده های موجود است (البرزی، ۱۳۸۰).

- 1- Equilibrium Moisture Content
- 2- Hysteresis
- 3- Blahovec & Yanniotis
- 4- Santalla & Mscheroni
- 5- Chayjan
- 6- Iglesias & Chirife
- 7- Peng *et al.*
- 8- Simal *et al.*
- 9- Artificial Neural Networks

- 10- Zbicinski
- 11- Islam *et al.*
- 12- Zhang *et al.*
- 13- Cubillos and Reyes
- 14- Progress

بذر و دانه آفتابگردان بر روی توری‌های مشبک روی محلول نمک اشباع قرار داده شد و هر سه روز وزن شد تا تغییرات وزن نمونه بین دو قرائت متوالی به کمتر از $g/10$ برسد. محتوای رطوبت نمونه‌ها در این مرحله به عنوان محتوای رطوبت تعادلی محسوب شد.

زمان لازم برای رسیدن نمونه‌ها به حالت تعادل، از یک تا شش هفته تغییر می‌کرد که به مغز یا بذر آفتابگردان، رطوبت نسبی و دما بستگی داشت. همه آزمایشها در سه تکرار انجام شد.

روش تحلیل آماری

چهار مدل ایزوترم جذب و دفع برای تحلیل داده‌های ERH-EMC برای بذرها و دانه‌های آفتابگردان استفاده شد که در جدول ۱ ارائه شده است.

در معادلات فوق، a_w فعالیت آبی (اعشاری)، EMC محتوای رطوبت تعادلی (% مبنای خشک)، T دمای مطلق (K)، R ثابت عمومی گازها (ژول بر مول کلونین)، A, B, C ثابت‌های معادلات برای مواد مختلف است که از طریق آزمایش مشخص می‌شود. برازش مدلها بر داده‌های آزمایشی به وسیله رگرسیون غیرخطی بر مبنای حداقل میانگین مربعات به وسیله نرم‌افزار Statgraphics plus 4.1 انجام شد.

از معیارهای ضریب تبیین (R^2) ، خطای استاندارد (SE) و خطای نسبی میانگین (P) برای ارزیابی مدلهاى مختلف استفاده شد.

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

$$SE = \sqrt{\frac{\sum (S_k - T_k)^2}{df}} \quad [2] \quad P = \frac{100}{n} \sum_{k=1}^n \left| \frac{S_k - T_k}{T_k} \right| \quad (3)$$

S_k خروجی شبکه برای k امین الگو، T_k مقدار اندازه‌گیری شده برای الگوی k ام و n تعداد الگوهای آموزشی است.

کیلوگرمی در سال زراعی ۸۶-۱۳۸۵ از مزارع استان گلستان تهیه شد. بذر سالم به صورت دستی از ناخالصی‌ها و بذر شکسته و نارس جدا شدند. دانه و پوست توسط یک دستگاه پوست کن (یانمار مدل ST50 ساخت کشور ژاپن) جدا شد. پس از پوست کنی اولیه، پوست از دانه به راحتی و به صورت دستی جدا شده، دانه و بذر به صورت جداگانه در کیسه‌های پلاستیکی دو لایه بسته‌بندی شد، به طوری که با هوای محیط، تبادل رطوبتی نداشته و در دمای $5^\circ C$ در یخچال نگهداری شد. رطوبت اولیه محصول، 28.2 ± 2 درصد ماده خشک و رطوبت اولیه برای فرایند جذب، حدود 27.0 ± 0.2 درصد ماده خشک بود. دسته‌بندی نمونه‌های بذر و دانه‌ها برای فرایند جذب در محفظه‌ای با دمای $10^\circ C$ و رطوبت نسبی کم (حدود ۱۱٪) انجام شد تا محتوای رطوبتی کم حاصل شود. برای فرایند دفع، با افزودن مقدار محاسبه شده آب مقطر با افشانک به دانه‌ها و بذر و هم‌زدن متناوب محتویات با دستگاه همزن در طی ۴۸ ساعت نمونه‌ها به دست آمد. سپس نمونه‌ها را در یک کیسه پلاستیکی قرار دادیم و برای جلوگیری از فساد نمونه‌ها، آنها را در دمای $5^\circ C$ داخل یخچال نگهداری کردیم. قبل از شروع آزمایش، نمونه‌ها را از یخچال خارج کرده و مدتی در داخل اتاق قرار دادیم تا به دمای محیط برسد. محتوای رطوبتی دانه و مغز با روش ثقلی و به کمک یک دستگاه آون در دمای $103^\circ C$ و مدت ۲۴ ساعت انجام گرفت (استاندارد ای‌اس‌ای ۱، ۲۰۰۴).

روش استاتیکی با محلولهای استاندارد برای ایجاد فشار بخار ثابت در دمای ثابت بکار رفت تا محتوای رطوبت تعادلی در محصول ایجاد شود (گبس و همکاران^۲، ۱۹۹۹). محفظه شیشه‌ای حامل نمک‌های اشباع در آون و در دماهای ۱۰، ۲۵، ۴۰ و $55^\circ C$ قرار داده شد تا رطوبت‌های نسبی بین ۱۱ تا ۹۶٪ ایجاد شود.

جدول ۱- مدل ایزوترم جذب و دفع برای تحلیل داده‌های ERH-EMC برای بذرهای آفتابگردان

مدل ایزوترم	نام مدل
$EMC = \frac{1}{B} \left[\ln \frac{A}{R(T+C)} - \ln(-\ln a_w) \right]$	(چانگ-پی فاست اصلاح شده)
$EMC = \frac{A \cdot \exp\left(\frac{A_1}{T}\right) BC.RH}{[(1-B.RH)(1-B.RH+BC.RH)]}$	(G.A.B.)
$EMC = \left[\frac{-\exp(A+BT)}{\ln a_w} \right]^{\frac{1}{C}}$	(هالسی اصلاح شده)
$EMC = \left[-\frac{1}{A.(T+C)} \cdot \ln(1-a_w) \right]^{\frac{1}{B}} \cdot 10^{-2}$	(هندرسون اصلاح شده)

مدل های هندرسون اصلاح شده، چانگ-پی فاست اصلاح شده و هالسی اصلاح شده، مدل‌های سه متغیری هستند اما مدل GAB چهار متغیری است. ضرایب مدل‌ها با استفاده از مدل غیر خطی نرم‌افزار تعیین شد.

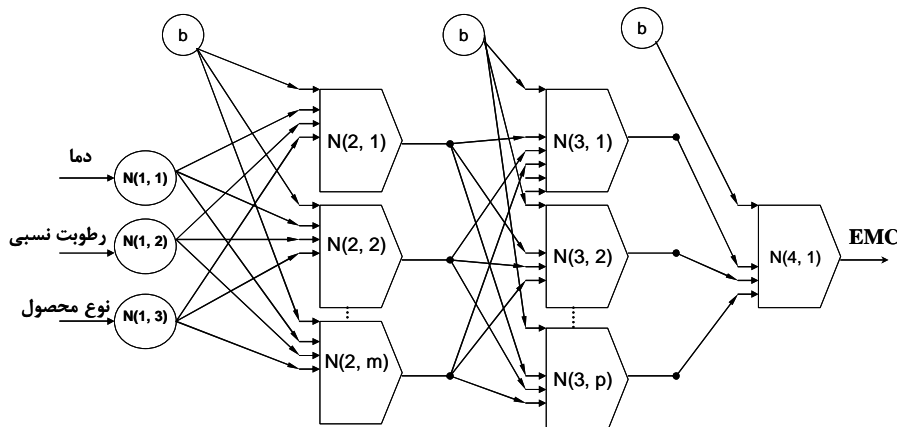
طراحی شبکه‌های عصبی مصنوعی و چگونگی روند آموزش

ساختار عمومی شبکه‌های عصبی چندلایه در شکل ۱ نشان داده شده است. لایه اول سه نرون دارد که برابر با تعداد ورودی‌ها است و با نماد $N(1, 1)$ ، $N(1, 2)$ و $N(1, 3)$ نشان داده می‌شود. لایه دوم m نرون دارد که لایه پنهان اول است و $N(2, 1)$ ، $N(2, 2)$ ، $N(2, 3)$ ، $N(2, 4)$ ، $N(2, 5)$ ، $N(2, 6)$ نامگذاری می‌شود. لایه سوم p نرون دارد و شامل نرون‌های $N(3, 1)$ ، $N(3, 2)$ ، $N(3, 3)$ ، $N(3, 4)$ ، $N(3, 5)$ ، $N(3, 6)$ است.

نرون‌های لایه اول، سه سیگنال ورودی را به شکل بردار $X = [x_1 \ x_2 \ x_3]^T$ دریافت می‌کنند که برابر است با: $x_1 = T_{en}$ (دمای تعادلی)،

یا $x_2 = RH_{en}$ (رطوبت نسبی تعادلی) و $x_3 = V$ (کد ۰ یا ۱ بترتیب برای مغز یا بذر آفتابگردان). خروجی نرون‌های لایه ورودی به شکل $Z = [z_1 \ z_2 \ z_3]^T$ است که به لایه پنهان دوم ارسال می‌شود. در نهایت خروجی شبکه به صورت بردار $Y = [y]^T$ خواهد بود که: $EMC = y$. وزن‌های متناظر با نرون $N(1, i)$ در لایه اول $(i=1, 2, 3)$ ، $(w_{i1}^{(1)}, w_{i2}^{(1)}, w_{i3}^{(1)})$ ، وزن‌های متناظر با نرون $N(2, j)$ در لایه دوم $(j=1, 2, \dots, m)$ ، $(w_{j1}^{(2)}, w_{j2}^{(2)}, \dots, w_{jm}^{(2)})$ و وزن‌های متناظر با نرون $N(3, k)$ در لایه سوم $(k=1, 2, \dots, p)$ ، $(w_{k1}^{(3)}, w_{k2}^{(3)}, \dots, w_{kp}^{(3)})$ است.

$$MSE = \frac{\sum_{p=1}^M \sum_{i=1}^N (S_{ip} - T_{ip})^2}{n_p \times n_o} \quad (۴)$$



شکل ۱- ساختار عمومی شبکه عصبی مصنوعی مورد استفاده

که در آن، MSE خطای میانگین مربعات 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_p تعداد الگوها، n_o تعداد نرون‌های لایه خروجی، N تعداد نرونهای خروجی و M تعداد الگوهای آموزشی است. هدف آن است که میزان این خطا به کمترین مقدار ممکن برسد.

برای ارزیابی یادگیری شبکه‌های عصبی و حصول بهترین نتایج، از چندین معیار استفاده شد. مقادیر آماری برای ارزیابی قابلیت تعمیم عبارتند از ضریب تبیین (R^2)، خطای استاندارد (SE) و خطای نسبی میانگین (P).

توابع آستانه^۶ مختلفی برای یافتن حالت بهینه شبکه‌ها مورد ارزیابی قرار گرفت که عبارتند از: تابع سیگموئید لگاریتمی (LOGSIG)، تابع خطی (PURELIN) و تابع تانژانت هایپربولیک سیگموئید (TANSIG). الگوریتم آموزش بکاررفته برای بهنگام‌سازی وزنهای شبکه‌ها، الگوریتم لونیبرگ-مارکوآرت^۷ (LM) است که بر مبنای ماتریس هسین^۸ است و به شبکه اجازه

به منظور بررسی و ارزیابی شبکه‌های مختلف، پایگاه داده‌ای به دو قسمت تقسیم شد: آموزش^۱، ارزیابی^۲. برای پیدا کردن بهترین پیش‌بینی‌ها، شبکه‌های مختلفی بر داده‌های مذکور اعمال شدند. شایان ذکر است که الگوهای ارزیابی برای بررسی عملکرد تعمیم شبکه‌های بکاررفته استفاده می‌شود (دیموت و همکاران^۳، ۲۰۰۷). حدود ۲۵ درصد معادل الگوهای آموزش که ۱۶ آزمایش مستقل است برای ارزیابی شبکه‌های آموزش دیده و بقیه برای آموزش استفاده شد. از ابزارهای نرم‌افزار MATLAB 7 بنام Neural Networks Toolbox (نسخه ۴/۰۱) برای طراحی و ارزیابی شبکه‌های عصبی مصنوعی مختلف استفاده شد.

در این مرحله، مدل‌های شبکه عصبی آموزش دیده به وسیله مجموعه داده‌های ارزیابی که مستقل از داده‌های آموزش است مورد آزمون قرار گرفت. برای یافتن شبکه‌ای با معماری مناسب به کمک الگوریتم‌های آموزشی، از معیار خطای میانگین مربعات^۴ استفاده شد (هریستف^۵، ۱۹۹۸):

- 1- Train
- 2- Test
- 3- Demuth *et al.*
- 4- Mean Square Error
- 5- Heristev

- 6- Threshold Function
- 7- Levenberg-Marquardt
- 8- Hessian Matrix

خطای نسبی برای مدل مذکور، کمترین مقدار و ضریب تبیین بیشترین مقدار بود. ضرایب، خطای استاندارد محتوای رطوبت تعادلی، ضریب تبیین و خطای نسبی برای مدل GAB در جدول ۳ نشان داده شده است.

با مقایسه نتایج جدول های ۲ و ۳ می توان دریافت که مدل های هالسی و GAB بهترین عملکرد را در برازش داده های آزمایشی داشته اند. نتایج مربوط به برازش برای مدل های مذکور در هر دما برای بذور و دانه ها بیانگر برتری مدل GAB نسبت به مدل هالسی اصلاح شده است. زیرا مقادیر R^2 بیشتر و مقادیر P و SE کمتری نسبت به مدل های دیگر تولید شده است.

شبکه های عصبی مصنوعی

دو راهبرد برای بررسی تأثیر توابع فعال سازی مختلف برای بهینه سازی شبکه های مورد استفاده به کار گرفته شد: یکی توابع فعال سازی یکسان برای لایه ها و دیگری توابع فعال سازی غیریکسان برای لایه ها. در شرایط توابع یکسان برای تمام لایه ها در شبکه CFBP، الگوریتم LM در اکثر موارد دچار وراآموزی^۱ شد یا قادر به یادگیری داده های آموزشی نبود (جدول ۴ و ۵). تابع فعال سازی تانژانت هایپربولیک (TANSIG) برای تمام لایه ها نسبت به توابع فعال سازی سیگموئید (LOGSIG) و خطی (PURELIN) نتایج بهتری داشت. در شرایط کلی، توپولوژی سه لایه نسبت به توپولوژی چهار لایه نتایج بهتری ارائه داد. در جدول ۴ مشاهده می شود که با توپولوژی ۱-۵-۳ و تابع فعال سازی TANSIG بهترین نتایج برای شبکه CFBP در راهبرد اول به دست آمد که خطای آموزش آن ۰/۰۰۰۸۳ بود. در این شرایط، کمترین مقدار خطای نسبی ۱۱/۷۸ و بیشترین مقدار ضریب تبیین، ۰/۹۷۰ بود. تعداد چرخه آموزش آن نیز ۱۶ بود.

می دهد تا با دقت بیشتری الگوها را فرا بگیرد. برای هنجارسازی تمامی عناصر موجود در یک الگو، داده های مربوطه به دامنه های [۰، ۱] و [۱، -۱] تبدیل شدند.

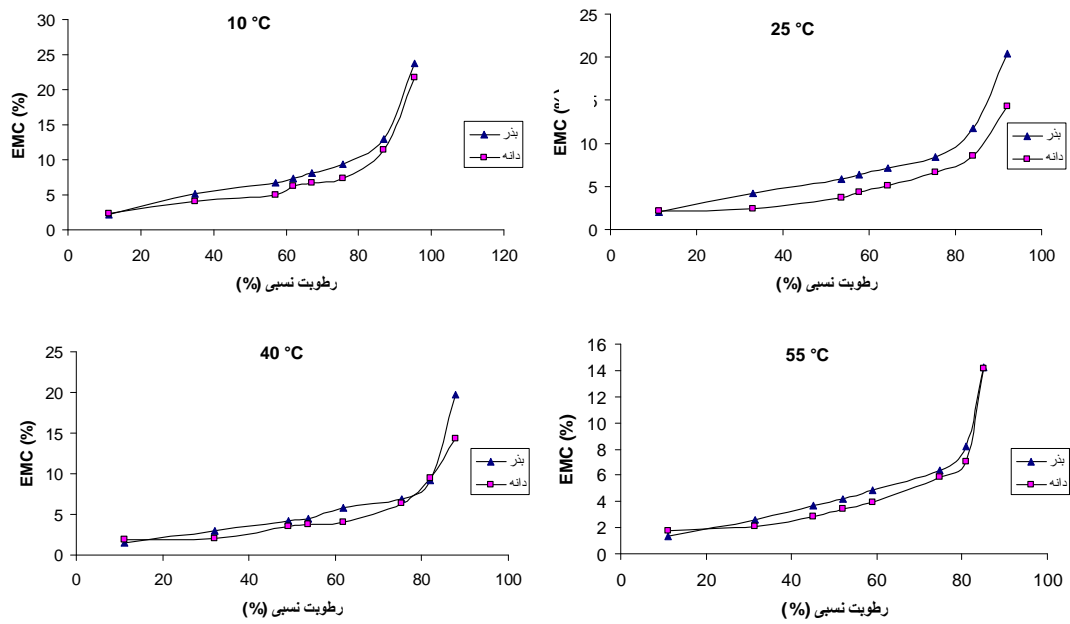
نتایج و بحث

مدل های تجربی


مشخصات آفتابگردان مورد استفاده در این پژوهش عبارت است از: حجم روغن بذور $0.94 \pm 0.43/6\%$ ، حجم روغن دانه $0.52 \pm 0.60/13\%$ ، نسبت پوست به دانه (وزن ماده خشک) 0.531 و حجم اسید اولوئیک $0.80/25\%$. مقدار میانگین EMC برای بذور و دانه های آفتابگردان در دماها و رطوبت نسبی های مختلف در شکل ۲ ارائه شده است. داده های به دست آمده تا رطوبت نسبی ۸۰٪، اختلاف کمی با مقادیر پیش بینی داشتند. مقادیر EMC در این تحقیق، کمتر از مقادیر مورد نظر برای بذور آفتابگردان روغنی توسط مازا و جایاس (۱۹۹۱) است. که این امر به دلیل تفاوت در میزان روغن موجود در دانه های آفتابگردان و بافت پوست و دانه آنهاست. زیرا با افزایش میزان روغن موجود در دانه آفتابگردان، رطوبت تعادلی آن کاهش می یابد.

رطوبت تعادلی دانه های آفتابگردان روغنی، کمتر از بذرهاست (شکل ۳)، زیرا حجم روغن آن بیشتر است که توسط مازا و جایاس (۱۹۹۱) نیز گزارش شده است. پدیده پس ماند وقتی مشاهده می شود که بذرها با رطوبت اولیه کمتر یا بیشتر در محیط محلول نمک اشباع 25°C به سمت نقطه تعادل رطوبتی می رود (شکل ۳). برای دانه ها نیز این پدیده برای رطوبت نسبی بالاتر از ۷۵٪ مشهود است.

ضرایب خطای استاندارد محتوای رطوبت تعادلی، ضریب تبیین و خطای نسبی برای سه مدل هندرسون اصلاح شده، چانگ-پی فاست اصلاح شده و هالسی اصلاح شده در جدول ۲ نشان داده شده است. مدل هالسی، بهترین نتایج را در برازش داده های آزمایشی برای دانه و بذور نشان داد. زیرا خطای استاندارد EMC و



شکل ۲- میانگین رطوبت تعادلی در رطوبت‌های نسبی در محدوده ۱۱ تا ۹۶٪ و دماهای ۱۰، ۲۵، ۴۰ و ۵۵°C برای بذر و مغز دانه آفتابگردان



شکل ۳- پدیده پسماند در بذر و مغز آفتابگردان در دمای ۲۵°C

جدول ۲- ضرایب مدل های هندرسون اصلاح شده، چانگ-پی فاست و هالسی برای بذر و دانه های آفتابگردان

دانه		بذر				ضرایب
هندرسون	چانگ-پی فاست	هالسی	هندرسون	چانگ-پی فاست	هالسی	
۰/۰۰۰۳۵۴	۲۶۷/۶۳۵۵۶۸	۱/۷۴۸۲۳۴	۰/۰۰۰۴۳۸	۲۳۵/۲۱۲۳۳	۲/۱۷۱۷۲۱	A
۰/۷۵۵۶۱۲	۲۴/۷۹۵۴۸	۰/۰۰۳۱۲۴	۰/۹۲۷۷۶۵	۱۹/۸۵۷۶۳۵	۰/۰۰۰۳۰۲	B
۶۳۲/۱۸۹۶	۹۹/۱۵۸۶۲۱	۱/۶۲۵۴۸۷	۳۸۷/۷۹۵۴	۸۴/۵۶۴۲۸۷	۱/۷۱۵۴۷۸	C
۱/۳۳	۱/۹۱	۱/۲۳	۱/۶۲	۲/۰۵	۱/۵۸	SE
۱۲/۵	۷/۵۹	۷/۱	۱۱/۴	۱۱/۲	۹/۶	P
۹۰/۳	۸۰/۶	۹۲/۴	۸۸/۵	۸۲/۹	۹۰/۵	R ²

در شرایط راهبرد توابع فعال سازی غیریکسان برای شبکه FFBP (جدول ۷) بهترین نتیجه در شرایط توابع فعال سازی LOGSIG-PURELIN برای توپولوژی ۳-۳-۱ به دست آمد. توپولوژی مذکور خطای آموزش ۰/۰۱۰۴۷، خطای نسبی ۱۲/۴۴ و خطای استاندارد ۰/۸۵۲۴، با ضریب تبیین ۰/۹۷۵۴ تولید کرد. در این شرایط تعداد چرخه آموزش ۱۹ بود.

در میان چهار توپولوژی برتر انتخاب شده از جدول های ۴ تا ۷، بهترین نتایج، مربوط به شبکه CFBP و راهبرد توابع فعال سازی غیریکسان (TANSIG-LOGSIG) است که توپولوژی ۳-۱-۳-۵ را دارد، زیرا خطای آموزش کمتر (۰/۰۰۰۷۶)، ضریب تبیین بیشتر (۰/۹۹۳۳)، خطای نسبی (۵/۰۱)، و خطای استاندارد ۰/۴۲۵۲ را تولید می کند. تعداد چرخه آموزش این توپولوژی ۳۳ است. مقدار ضریب تبیین این توپولوژی بهینه در شکل ۴ و چگونگی یادگیری آن در شکل ۵ نشان داده شده است. روند یادگیری این شبکه بیانگر عدم واگرایی بین داده های آموزش و ارزیابی است که این امر سبب جلوگیری از وراآموزی توپولوژی بهینه می شود.

در شرایط توابع فعال سازی غیریکسان برای شبکه CFBP، توپولوژی ۳-۵-۳-۱ به طور متوسط دارای عملکرد بهتر و خطای کمتری است (جدول ۵). در این راهبرد از ترکیب های مختلف TANSIG، LOGSIG و PURELIN در توپولوژی های سه لایه و چهار لایه استفاده شد. بهترین نتایج در جدول ۵ نشان داده شده است. توپولوژی ۳-۵-۳-۱ با ترتیب توابع فعال سازی TANSIG - LOGSIG - TANSIG نسبت به چند توپولوژی دیگر، دارای ضریب تبیین بیشتر (۰/۹۹۳۵)، خطای نسبی (۵/۰۱) و خطای استاندارد کمتری (۰/۴۲۵۲) نسبت به آنهاست.

در شرایط توابع فعال سازی یکسان برای شبکه FFBP، توپولوژی های چهار لایه دارای عملکرد بهتری بودند (جدول ۶). استفاده از تابع فعال سازی TANSIG نتایج بهتری نسبت به تابع LOGSIG ارائه داد. توپولوژی های سه لایه در الگوریتم LM نتایج ضعیف تری نسبت به انواع چهار لایه ارائه دادند. بهترین نتایج توپولوژی های این راهبرد مربوط به توپولوژی ۳-۵-۳-۱ است که خطای آموزش ۰/۰۰۱۱۷، ضریب تبیین ۰/۹۸۴۱، خطای نسبی ۸/۲۹ و خطای استاندارد ۰/۶۵۶۵ تولید کرد. تعداد چرخه آموزش برای حصول این نتیجه ۲۴ است.

جدول ۳- ضرایب و معیارهای مدل اصلاح شده GAB برای بذر و دانه آفتابگردان

دانه	بذر	ضرایب
۱/۸۸۳۱	۱/۸۹۲۱	A ₀
۲۶/۲۷۸	۱۱۲/۳۲۸	A ₁
۰/۹۲۵۸	۰/۹۱۴۵	B
۴۷/۴۵۸۷	۱۲/۸۹۴۵	C
۱/۱۳	۱/۳۴	SE
۷/۴۲	۷/۱۱	P
۹۷/۱۵	۹۷/۱۰	R ²

جدول ۴- مقادیر خطای آموزش برای شبکه CFBP برای مقادیر مختلف تعداد لایه‌ها و نرون‌ها و توابع فعال‌سازی یکسان برای لایه‌ها

چرخه آموزش	P	SE	R ²	MSE	تعداد لایه‌ها و نرون‌ها	تابع فعال‌سازی
۱۶	۱۱/۷۸	۰/۸۷۹۴	۰/۹۷۰۰	۰/۰۰۰۸۳	۳-۵-۱	TANSIG
۱۴	۱۲/۵۶	۱/۰۴۷	۰/۹۵۴۸	۰/۰۰۰۴۸	۳-۵-۱	LOGSIG
۳۰	۱۴/۵۸	۱/۱۸	۰/۹۵۴۹	۰/۰۰۰۳۱	۳-۳-۲-۱	TANSIG
۲۲	۹/۰۸	۱/۰۴۷۷	۰/۹۵۹۱	۰/۰۰۰۰۵۱	۳-۵-۳-۱	LOGSIG

جدول ۵- مقادیر خطای آموزش برای شبکه CFBP برای مقادیر مختلف تعداد لایه‌ها و نرون‌ها و توابع فعال‌سازی غیر یکسان برای لایه‌ها

چرخه آموزش	P	SE	R ²	MSE	تعداد لایه‌ها و نرون‌ها	تابع فعال‌سازی
۳۷	۱۲/۸۵	۰/۹۴۸۹	۰/۹۶۶۲	۰/۰۰۰۸۹۷	۳-۵-۱	LOGSIG-TANSIG
۳۴	۱۲/۰۰	۰/۹۵۲۸	۰/۹۶۷۵	۰/۰۰۰۵۹۸	۳-۵-۱	LOGSIG-PURELIN
۲۱	۹/۱۱	۰/۷۰۹۳	۰/۹۸۱۴	۰/۰۰۰۱۵	۳-۳-۲-۱	TANSIG- TANSIG- LOGSIG
۳۳	۵/۰۱	۰/۴۲۵۲	۰/۹۹۳۳	۰/۰۰۰۰۷۶	۳-۵-۳-۱	TANSIG- TANSIG- LOGSIG

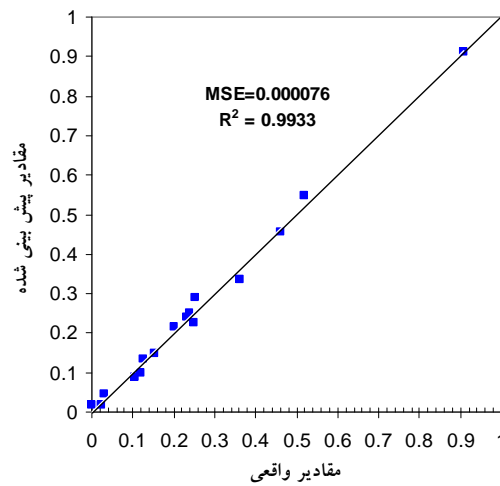
جدول ۶- مقادیر خطای آموزش برای شبکه FFBP در شرایط مقادیر مختلف تعداد لایه‌ها و نرون‌ها و توابع فعال‌سازی یکسان برای لایه‌ها

چرخه آموزش	P	SE	R ²	MSE	تعداد لایه‌ها و نرون‌ها	تابع فعال‌سازی
۱۷	۱۴/۹۳	۰/۱۲۹۲	۰/۹۶۰۰	۰/۰۰۱۰	۳-۳-۱	TANSIG
۱۸	۱۳/۱۷	۰/۱۲۱۵	۰/۹۳۲۵	۰/۰۰۰۸۹	۳-۳-۱	LOGSIG
۴۹	۸/۸۰	۰/۶۷۹۳	۰/۹۸۲۴	۰/۰۰۰۴۲	۳-۵-۴-۱	LOGSIG
۲۴	۸/۲۹	۰/۶۵۶۵	۰/۹۸۴۱	۰/۰۰۰۱۱۷	۳-۵-۳-۱	TANSIG

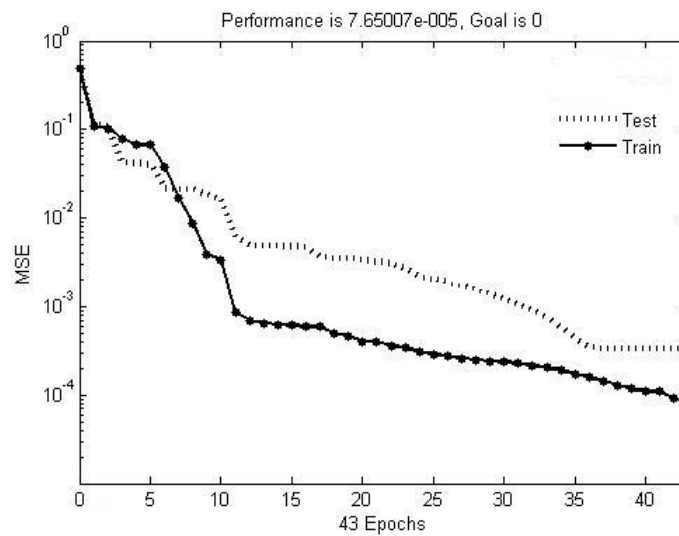
جدول ۷- مقادیر خطای آموزش برای شبکه FFBP برای مقادیر مختلف تعداد لایه‌ها و نرون‌ها و توابع فعال‌سازی غیر یکسان برای لایه‌ها

چرخه آموزش	P	SE	R ²	MSE	تعداد لایه‌ها و نرون‌ها	تابع فعال‌سازی
۲۰	۱۲/۷۲	۰/۸۴۴۷	۰/۹۷۱۸	۰/۰۰۰۹۶	۳-۳-۱	TANSIG- PURELIN
۱۹	۱۲/۴۴	۰/۸۵۲۴	۰/۹۷۵۴	۰/۰۰۱۰۴۷	۳-۳-۱	LOGSIG- PURELIN
۲۵	۱۲/۱۲	۰/۸۷۱۶	۰/۹۶۸۸	۰/۰۰۰۸۸	۳-۵-۴-۱	TANSIG- LOGSIG- TANSIG
۲۳	۱۵/۸۴	۱/۲۷	۰/۹۵۲۷	۰/۰۰۰۱۷	۳-۵-۳-۱	LOGSIG- LOGSIG- TANSIG

امیری چایجان و امیری پریان: پیش بینی مشخصه های رطوبت تعادلی آفتابگردان...



شکل ۴- رطوبت تعادلی مربوط به بذر و دانه پیش بینی شده با روش شبکه عصبی مصنوعی در مقابل مقادیر واقعی آن برای توپولوژی بهینه



شکل ۵- چگونگی فرایند یادگیری شبکه بهینه

ماتریس های بین لایه ها و بایاس ها برای توپولوژی

بهینه عبارت است از:

$$iw\{2,1\} = \begin{bmatrix} -4/478 & 1/042 & 6/999 \\ 0/746 & -0/924 & -2/947 \\ 6/349 & 3/838 & -3/022 \\ -1/001 & 1/3717 & 13/394 \\ -1/438 & 6/844 & 5/179 \end{bmatrix}$$

(وزن بین لایه های ۱ و ۲)

$$\begin{aligned}
 iw\{3,1\} &= \begin{bmatrix} -3/660 & -0/297 & -1/024 \\ 2/332 & -0/810 & 0/567 \\ 0/763 & 6/606 & -0/709 \end{bmatrix} \text{ (وزن بین لایه‌های ۱ و ۳)} \\
 iw\{4,1\} &= [-0/758 \quad 0/412 \quad 5/685] \text{ (وزن بین لایه‌های ۱ و ۴)} \\
 iw\{3,2\} &= \begin{bmatrix} -3/903 & 1/614 & -1/974 & 3/742 & 1/743 \\ 3/405 & -2/060 & 1/738 & 0/514 & 3/217 \\ 5/841 & -6/388 & 4/372 & 1/268 & 8/308 \end{bmatrix} \text{ (وزن بین لایه‌های ۲ و ۳)} \\
 iw\{4,2\} &= [-8/228 \quad 3/365 \quad -1/980 \quad 5/067 \quad -7/624] \text{ (وزن بین لایه‌های ۲ و ۴)} \\
 iw\{4,3\} &= [-1/745 \quad 2/031 \quad 0/425] \text{ (وزن بین لایه‌های ۳ و ۴)} \\
 b\{2\} &= \begin{bmatrix} -7/488 \\ 0/738 \\ -4/800 \\ -12/982 \\ 4/153 \end{bmatrix} \text{ (بایاس لایه ۲)} \\
 b\{3\} &= \begin{bmatrix} 4/396 \\ 2/532 \\ 8/530 \end{bmatrix} \text{ (بایاس لایه ۳)} \\
 b\{4\} &= [0/072] \text{ (بایاس لایه ۴)}
 \end{aligned}$$

خواهد بود. از ماتریس‌های ارائه شده نیز می‌توان به عنوان مدلی برای پیش‌بینی رطوبت تعادلی نمونه‌های آفتابگردان (بذر و مغز) در محدوده دما و رطوبت نسبی اعمال شده در این پژوهش استفاده کرد. به عبارت دیگر برای پیش‌بینی رطوبت تعادلی نمونه‌های آفتابگردان به کمک شبکه‌های عصبی نیز می‌توان از ماتریس‌های بهینه حاصله استفاده کرد.

دلیل تفاوت ماتریس‌های وزنی از نظر ابعاد در لایه‌های مختلف به دلیل تفاوت در تعداد نرونها در لایه‌های مختلف است. به عنوان مثال تعداد نرون‌های لایه اول ۳ تا و تعداد نرون‌های لایه دوم ۵ تا است، بنابراین ماتریس ضرایب وزنی بین لایه‌های اول و دوم 5×3 است. توپولوژی بهینه انتخاب شده دارای ساختار متعادل است لذا دارای پایداری مناسبی از لحاظ ارائه نتایج

منابع

۱. البرزی، م. ۱۳۸۰. آشنایی با شبکه‌های عصبی. (تالیف بیل و جکسون) چاپ اول. انتشارات دانشگاه صنعتی شریف، ۱۳۷ ص.
2. ASAE Standard. 2004. Standard Engineering Practice Data. 49th Ed., American Society of Agricultural Engineering. St. Joseph, USA. 1194 p.
3. Blahovec, J., Yanniotis, S. 2009. Modified classification of sorption isotherms. Journal of Food Engineering, 91(1): 72-77.
4. Chayjan, R.A. 2010. Modeling of sesame seed dehydration energy requirements by a soft-computing approach. Australian Journal of Crop Science, 4(3): 180-184.

5. Cubillos, F., and Reyes, A. 2003. Drying of Carrots in a fluidized bed. II. Design of a model based on a modular neural network approach. *Drying Technology*, 21(7): 1185-1196.
6. Demuth, H., Beale, M., Hagan, M. 2007. *Neural network toolbox 5*. The MathWorks, Natick, MA, USA. 906 p.
7. Gabas, A.L., Telis-Romero, J., and Menegalli, F.C. 1999. Thermodynamic models for water sorption by grape skin and pulp. *Drying technology*, 17, 961-974.
8. Gupta, R.K., and Das, S.K. 1997. Physical properties of sunflower seeds. *Journal of Food Engineering*, 66: 1-8.
9. Heristev, R.M. 1998. *The ANN Book*. GNU Public License, USA. Pp. 681.
10. Iglesias, H.A., and Chirife, J. 1976. Prediction of effect of temperature on water sorption isotherm of food materials. *Journal of Food Technology*, 11:109-116.
11. Islam, M.R., Sablani, S.S., and Mujumdar, A.S. 2003. An artificial neural network model for prediction of drying rates. *Drying Technology*, 21(9): 1867-1884.
12. Mazza, G., and Jayas, D.S. 1991. Equilibrium moisture characteristics of sunflower seed, hulls and kernels. *Transactions of the ASAE*, 34(2): 534-538.
13. Peng, G., Chen, X., Wu, W., and Jiang, X. 2007. Modeling of water sorption isotherm for corn starch. *Journal of Food Engineering*, 80: 562-567.
14. Santalla, E.M., and Mascheroni, R.H. 2003. Physical properties of high oleic sunflower seed. *Food Science and Technology International*, 9(6): 435-442.
15. Simal, S., Femenia, A., Castell-Palou, A., and Rosselló, C. 2007. Water desorption thermodynamic properties of pineapple. *Journal of Food Engineering*, 8(4): 1293-1301.
16. Zbicinski, I., and Ciesielski, K. 2000. Extension of the neural networks operating range by the application of dimensionless numbers in prediction of heat transfer coefficients. *Drying Technology*, 18(3): 649-660.
17. Zbicinski, I., Strumillo, P., and Kaminski, W., 1996. Hybrid neural model of thermal drying in a fluidized bed. *Computers in Chemical Engineering*, 20: 695-700.
18. 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.