



پیش‌بینی هوشمند و لحظه‌ای محتوای رطوبتی با استفاده از شبکه عصبی مصنوعی در فرآیند خشک کردن لایه نازک پسته

سلیمان حسین‌پور^۱، شاهین رفیعی^۲ و مهدی کاشانی‌نژاد^۳

^۱دانشجوی دکتری گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشگاه تهران، ^۲دانشیار گروه مهندسی ماشین‌های کشاورزی، دانشگاه تهران، ^۳دانشیار گروه علوم و صنایع غذایی، دانشگاه کشاورزی و منابع طبیعی گرگان

تاریخ دریافت: ۱۳۸۹/۱۱/۰۴؛ تاریخ پذیرش: ۱۳۹۰/۰۴/۱۳

چکیده

در این پژوهش به بررسی پیش‌بینی محتوای رطوبتی پسته به صورت لحظه‌ای در طول فرآیند خشک کردن براساس ترکیب‌هایی از مقادیر محتوای رطوبتی زمان‌های قبلی و با استفاده از شبکه‌های عصبی مصنوعی پرداخته شده است. به‌منظور به‌دست آوردن داده‌های آزمایشگاهی، پسته (رقم واحدی) در چهار سطح دمایی (۲۵، ۴۰، ۵۵ و ۷۰ درجه سانتی‌گراد)، سه سطح سرعت جریان هوا (۰/۵، ۱ و ۱/۵ متر بر ثانیه) و دو سطح رطوبت نسبی هوا (۵ و ۲۰ درصد) خشک و محتوای رطوبتی نمونه‌ها با گذشت زمان در این شرایط اندازه‌گیری شد. دما هواخشک کن بیشترین تأثیر را در فرآیند خشک کردن لایه نازک پسته داشت ($P < 0.01$). این در حالی است که اثر سرعت جریان هوا و رطوبت نسبی هوا در فرآیند خشک کردن ناچیز ارزیابی شد. ضریب پخش مؤثر براساس دمای جریان هوا از 10^{-11} تا 10^{-10} مترمربع بر ثانیه، متغیر بود. به‌منظور بررسی پیش‌بینی محتوای رطوبتی پسته در طول فرآیند خشک کردن براساس مقادیر محتوای رطوبتی زمان‌های قبلی، محتواهای رطوبتی به عنوان یک سری زمانی در نظر گرفته شده و با استفاده از سه نوع شبکه عصبی طراحی شده که همگی آن‌ها از نوع سه لایه (با یک لایه مخفی) می‌باشند به پیش‌بینی محتوای رطوبتی پرداخته شده است. بهترین شبکه عصبی به‌دست آمده شبکه عصبی سه لایه از نوع اول با ۱۱ نرون در لایه مخفی برای تمامی ضرایب آموزشی بود که توانست به صورت لحظه‌ای محتوای رطوبتی را در ضمن انجام

* مسئول مکاتبه: shahinrafee@ut.ac.ir

آزمایش پیش‌بینی کند. مقدار ماکزیمم RMSE شبکه برای تمامی وضعیت‌های خشک کردن ۰/۲۳ و مقدار ماکزیمم واریانس خطاهای ۰/۱۳ به دست آمد. عملکرد شبکه به این صورت است که با داشتن سه محتوا رطوبتی می‌تواند چهارمین مقدار محتوای رطوبتی را پیش‌بینی کند و هنگامی که شبکه مقدار واقعی زمان چهارم را از فرآیند دریافت می‌کند با توجه به خطا بین مقدار پیش‌بینی و مقدار حقيقی، شبکه دوباره آموزش می‌بیند و به این ترتیب آموزش شبکه تا پایان فرآیند ادامه می‌يابد. شبکه عصبی به دست آمده به رغم این‌که در طول فرآیند خشک کردن به صورت لحظه‌ای آموزش می‌بیند و تغییر می‌کند یک پیش‌بینی‌کننده بسیار خوب برای محتوای رطوبتی می‌باشد که پس از گذشت مدت زمان کوتاهی از فرآیند خشک کردن، به سرعت الگوی فرآیند را یاد گرفته و پارامترهای آن ثابت می‌ماند و به جز در بازه کوتاهی از زمان‌های اولیه فرآیند که در آن زمان‌ها به طور معمول لازم نیست کنترلی روی فرآیند صورت بگیرد، عمل پیش‌بینی محتوای رطوبتی را در بقیه زمان‌ها با دقت بسیار بالایی انجام می‌دهد. از شبکه به دست آمده می‌توان به عنوان کنترل‌کننده که قابلیت آموزش لحظه‌ای در طول فرآیند خشک کردن را دارد و یا به عنوان واحد مشتق‌گیر در فرآیند خشک شدن استفاده نمود.

واژه‌های کلیدی: پسته، محتوای رطوبتی، پیش‌بینی‌کننده، لحظه‌ای، شبکه عصبی مصنوعی

مقدمه

خشک کردن یکی از فرآیندهای متداول در صنایع غذایی به حساب می‌آید و به احتمال زیاد اصلی‌ترین و پرهزینه‌ترین بخش در عملیات پس از برداشت می‌باشد^[۲]. از جمله مزایای خشک کردن محصولات کشاورزی افزایش زمان ماندگاری محصول بدون افرودن مواد شیمیایی، کاهش اندازه بسته‌بندی و کاهش هزینه حمل و نقل می‌باشد. کنترل بدون وقفه^۱ فرآیند خشک کردن و افزایش کیفیت محصول خروجی نیازمند پیش‌بینی بدون وقفه تغییرات محتوای رطوبتی می‌باشد. مدل‌های به دست آمده اغلب به منظور مطالعه رفتار متغیرهای عملیاتی، پیش‌بینی سیستیک خشک شدن و بهینه‌سازی فرآیند خشک کردن مورد استفاده قرار می‌گیرند^[۷]. مدل‌های تجربی، سیستیک فرآیند خشک شدن را اغلب با استفاده از تقریب‌زنی توابع نمایی^[۱۴]، چندجمله‌ای‌های با درجه بالا^[۲۰] و رگرسیون غیرخطی در قالب معادله پیچ^[۱۱،۱۰،۳] به دست می‌آورند. میدلی و کوچوک^[۱۳] مدل‌سازی سیستیک خشک کردن

1- On-line

لایه نازک پسته‌های با پوست و بدون پوست را با استفاده از خشک‌کن‌های خورشیدی با جریان طبیعی و اجباری هوا انجام دادند. نتایج مطالعه مقایسه‌ای هشت مدل ریاضی، نیمه ثوری و تجربی با داده‌های تجربی نشان داد که مدل لگاریتمی برای توصیف خشک کردن پسته با جریان هوا اجباری هوای گرم و مدل توترم برای خشک کردن با جریان طبیعی هوا می‌تواند استفاده گردد. کاشانی‌نژاد و همکاران [۸] سیستمیک فرآیند خشک کردن پسته (رقم اوحدی) را مورد مطالعه و بررسی قرار داده و نتیجه گرفتند که مدل پیچ بیشترین برازش را در تقریب‌زنی مقدار محتوای رطوبتی از خود نشان می‌دهد. پیشرفت‌های اخیر در رشته نوروپیولوژی نشان داد که شبکه‌های عصبی مصنوعی توانایی بالایی در تقریب‌زنی توابع غیرخطی دارند [۱۲،۹]. شبکه‌های عصبی مصنوعی در بسیاری از بخش‌های علوم و صنایع غذایی به کار گرفته شده‌اند [۱۹،۱۷،۵]. پژوهش‌گران بسیاری در پژوهش‌های خود در بررسی فرآیند خشک شدن از شبکه‌های عصبی مصنوعی استفاده کرده‌اند [۲۱،۱۹،۱۷،۱۵،۱۴،۶،۵،۴،۳،۱].

تمامی پژوهش‌هایی که در بالا به آن‌ها اشاره شد از شبکه‌های عصبی مصنوعی چند لایه پیش‌خور برای تقریب‌زنی (رگرسیون‌گیری) سیگنال محتوای رطوبتی استفاده نموده‌اند و مدل‌سازی محسوب می‌شوند در حالی که در سیستم‌های کنترل هوشمند به پیش‌بینی لحظه‌ای و بدون وقفه محتوای رطوبتی نیاز می‌باشد. شبکه‌های عصبی مصنوعی طراحی شده در این پژوهش، به‌دلیل این‌که از محتواهای رطوبتی زمان‌های قبل به عنوان ورودی استفاده می‌کنند، می‌توانند به عنوان پیش‌بینی‌کننده محتوای رطوبتی در سیستم‌های کنترل که قابلیت یادگیری فرآیند را به صورت لحظه‌ای^۱ در همان زمان فرآیند خشک کردن دارند، به کار روند.

پسته به عنوان یک محصول استراتژیک جایگاه خاصی را در بین تولیدات کشاورزی کشورمان دارد می‌باشد. در شرایط کنونی حدود ۵۵ درصد از تولید و بیش از ۶۰ درصد از صادرات جهانی پسته در اختیار ایران می‌باشد [۱۸]. خشک کردن یکی از فرآیندهای بسیار مهم در فرآوری پسته می‌باشد. پسته اوحدی رقم متداول پسته در ایران می‌باشد. بنابراین مطالعه و بررسی فرایند خشک کردن این رقم و طراحی یک سیستم کنترل برای فرآیند خشک کردن پسته ضروری به نظر می‌رسد.

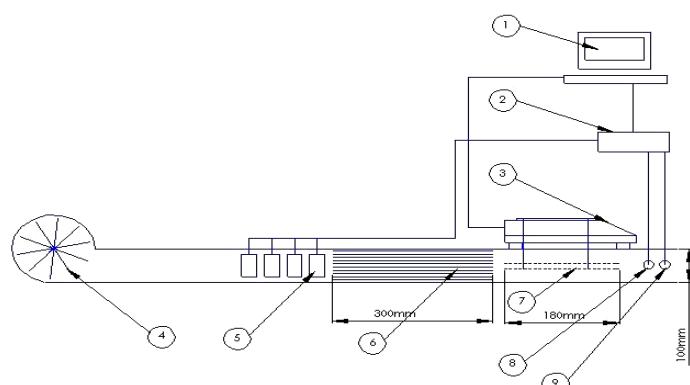
هدف اصلی از این پژوهش ارایه یک پیش‌بینی‌کننده محتوای رطوبتی در فرایند خشک کردن لایه نازک پسته می‌باشد که به صورت بلاذرنگ و لحظه‌ای می‌تواند در طول فرآیند خشک کردن خود را

1- Real time

تغییر داده و پس از گذشت مدت زمان کوتاهی از فرآیند خشک کردن (بسته به شرایط خشک کردن) روند فرآیند خشک کردن را آموزش دیده و عمل پیش‌بینی محتواهای رطوبتی در زمان‌های بعدی را بدون استفاده از اندازه‌گیری متغیرهای عملیاتی (دما، سرعت جریان هوا، رطوبت نسبی و...) و تنها با استفاده از محتواهای رطوبتی زمان‌های قبلی، با دقت بالایی انجام دهد. از برتری‌های دیگر این پیش‌بینی کننده امکان پیش‌بینی محتواهای رطوبتی در خارج از محدوده داده‌برداری می‌باشد در حالی که روش‌های رگرسیون‌گیری و تقریب‌زنی توابع، فقط در محدوده داده‌برداری صادق می‌باشند. پیش‌بینی کننده یاد شده می‌تواند در کنترل غیرخطی فرایند خشک کردن پسته به عنوان یک کنترل کننده لحظه‌ای هوشمند، پیش‌بینی کننده و مشتق‌گیر عمل نماید.

مواد و روش‌ها

تجهیزات خشک کن لایه نازک: در این پژوهش از یک دستگاه خشک کن آزمایشگاهی که در دانشکده کشاورزی و مهندسی بیوریسوس دانشگاه ساسکاچوان کانادا موجود بود، استفاده شد (شکل ۱). دستگاه خشک کن آزمایشگاهی نامبرده از یک سیستم کنترل سرعت جریان هوا، قسمت گرم کننده برخی، سیستم کنترل دمای هواخشک کن، فن الکتریکی، حسگرهای رطوبت و محفظه خشک کن تشکیل شده است. توزین نمونه‌ها نیز در طول فرایند خشک شدن با استفاده از یک ترازوی دیجیتالی با حساسیت ۰/۰۱ و ظرفیت ۳۰۰۰ گرم انجام گرفت.



۱- رایانه - ۲- میکروکنترلر - ۳- ترازوی دیجیتال - ۴- فن سانتریفیوژ - ۵- گرم کن ها - ۶- محفظه مستقیم کننده - ۷- سینی نمونه ها - ۸- حسگر دما - ۹- حسگر رطوبت

شکل ۱- طرح واره خشک کن آزمایشگاهی.

روش تهیه نمونه: پسته‌ها با میانگین محتوای رطوبتی بین ۴-۵ درصد بر پایه مرطوب تهیه شده و در کیسه‌های دو لایه پلی‌اتیلن به صورت در بسته در یخچال نگهداری شدند. قبل از شروع آزمایش‌ها محتوای رطوبتی نمونه‌ها به‌وسیله اضافه کردن تناوبی آب مقتصر به نمونه‌های پسته به مقدار ۳۶-۳۷ درصد بر پایه مرطوب رسانده شده و سپس درون یک ظرف شیشه‌ای در بسته به‌مدت ۱۰ روز و در دمای ۵ درجه سانتی‌گراد نگهداری شدند تا به تعادل برسند. در این بازه زمانی در دوره‌های زمانی مشخص به‌طور مرتب مخلوط نمونه‌ها هم‌زده می‌شد [۱۶]. قبل از انجام هر آزمایش ۲۵۰ گرم از نمونه‌ها از یخچال خارج و سپس درون یک کیسه پلاستیکی درون محیط آزمایشگاه قرار داده می‌شد تا به دمای محیط برسند.

انجام آزمایش‌ها: آزمایش‌های خشک کردن در چهار سطح دمایی (۲۵، ۴۰، ۵۵ و ۷۰ درجه سانتی‌گراد)، سه سطح سرعت جریان هوا (۰/۵، ۱ و ۱/۵ متر بر ثانیه) و دو سطح رطوبت نسبی هوا (۵ و ۲۰ درصد) و در سه تکرار برای پسته (رقم اوحدی) انجام شد. در طی فرایند خشک شدن، وزن نمونه‌ها به‌وسیله ترازوی متصل به رایانه و رطوبت و دمای هوای خشک‌کن در هر ۶۰ ثانیه اندازه‌گیری و ثبت می‌شد. خشک کردن تا رسیدن محتوای رطوبتی نمونه‌ها به مقدار ۵ درصد در پایه مرطوب ادامه داشت. سپس نمونه‌ها در داخل آون با دمای 2 ± 0.3 درجه سانتی‌گراد قرار داده شد و پس از خشک شدن به‌مدت ۲۴ ساعت وزن خشک نمونه‌ها به‌دست آمد. در نهایت نیز رطوبت نمونه‌ها طی فرایند خشک شدن توسط معادله زیر محاسبه شد:

$$M = \frac{W_W - W_d}{W_d} \quad (1)$$

که در آن M : رطوبت نمونه‌های پسته بر پایه خشک (kg/kg, d.b.), W_W : وزن نمونه‌ها در طی فرایند خشک شدن (kg) و W_d : وزن نمونه (kg) پسته خشک است.

شبکه عصبی مصنوعی با تاخیر زمانی: شبکه عصبی مصنوعی از مجموعه‌ای از واحدهای سازنده به‌نام نرون تشکیل شده است که به‌وسیله فرستادن سیگنال‌هایی با یکدیگر ارتباط برقرار می‌کنند. شبکه عصبی مصنوعی یک شبکه گسترده با پردازش موازی است که کارایی مشابهی مانند رفتار سلول‌های بیولوژیکی مغز دارد. کارکرد این شبکه‌ها به‌گونه‌ای است که در آن مجموعه پایگاه داده‌ها به دو بخش آموزش و ارزیابی تقسیم می‌شوند. هدف از آموزش در این شبکه‌ها تعیین وزن‌ها و بایاس‌ها در

اتصالات بین گره‌ای می‌باشد به‌طوری‌که شبکه بتواند مقدار واقعی خروجی را با دقت بالایی تقریب بزند. کارایی شبکه‌های عصبی مصنوعی به‌وسیله درصد خطای بین مقدار تخمین زده شده و مقدار واقعی یا به‌وسیله روش‌های آماری دیگر ارزیابی می‌شود. این شبکه‌ها از یک لایه گره‌های ورودی و یک یا چند لایه نرون‌های لایه مخفی و یک لایه نرون‌های خروجی تشکیل می‌شوند. رابطه بین نرون‌ها (وزن‌ها و بایاس‌ها) در ابتدا به‌وسیله اعداد کوچک تصادفی بارگذاری می‌شوند و سپس در طول مرحله آموزش این اعداد به‌وسیله قانون کلی کمترین کاهش گرادیان به‌روزرسانی می‌شوند. آموزش شبکه تا زمانی که خروجی شبکه با دقت بالایی مقدار واقعی آن را تخمین بزند ادامه می‌یابد. به‌منظور جلوگیری از آموزش بیش از حد^۱ شبکه بخشی از داده‌های آموزش، به عنوان داده‌های ارزیابی مقطعی^۲ استفاده می‌شود که به‌این روش توقف زودهنگام^۳ گفته می‌شود. پس از آموزش نیز از داده‌های ارزیابی برای ارزیابی شبکه عصبی به‌دست آمده استفاده می‌شود.

در بعضی از شبکه‌های عصبی به‌منظور یافتن ارتباط زمانی^۴ میان داده‌ها و همچنین کاهش حجم شبکه، برخی از مقادیر خروجی نرون‌ها و یا مقادیر خروجی زمان‌های قبلی آن نرون‌ها را به ورودی همان نرون و یا به ورودی نرون‌های دیگر در همان لایه و یا لایه‌های دیگر بر می‌گردانند که به‌اصطلاح به این نوع شبکه‌ها شبکه‌های عصبی با بازخورد زمانی^۵ (تاخیر زمانی) گفته می‌شود که در کنترل فرآیندها نقش بهسزایی دارند.

شبکه‌های عصبی با تاخیر زمانی را می‌توان به دو گروه کلی تقسیم نمود:

۱- شبکه‌های عصبی سلولی^۶ که در آن شبکه‌ها نرون‌های لایه مشابه نیز با یکدیگر ارتباط زمانی دارند.

۲- شبکه‌های عصبی زمان واقعی^۷ که در آن شبکه‌ها خروجی نرون‌های لایه خروجی و یا خروجی زمان‌های قبلی آن‌ها به عنوان ورودی به شبکه بازگشت داده می‌شوند.

-
- 1- Over training
 - 2- Cross validation
 - 3- Early stopping
 - 4- Temporal relationship
 - 5- Recurrent neural network
 - 6- Cellular neural networks
 - 7- Real-time recurrent networks

شبکه‌های عصبی مورد استفاده در این پژوهش همگی از نوع شبکه‌های با تاخیر زمانی و زمان واقعی بوده و به منظور طراحی، آموزش، ارزیابی مقطعی و تست این شبکه‌ها از تابع ساختاری network در محیط نرم‌افزار مطلب که امکان ایجاد هر نوع شبکه عصبی با ساختار دلخواه را فراهم می‌کند استفاده شده است.

برای جلوگیری از احتمال آموزش بیش از حد شبکه از تابع عملکرد اصلاح شده^۱ به جای MSE استفاده شده است که در آن علاوه بر میانگین مجموع مربعات خطای شبکه از میانگین مجموع مربعات وزن‌ها و بایاس‌ها (MSW) نیز استفاده می‌شود. معادلات مربوط به تابع عملکرد اصلاح شده در زیر آمده است:

$$F = MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (2)$$

$$MSEreg = \gamma MSE + (1 - \gamma) MSW \quad (3)$$

$$MSW = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (4)$$

که در آن‌ها، N : تعداد الگوهای آموزشی شبکه، a_i : مقدار خروجی شبکه، t_i : مقدار واقعی، w_j : مقدار وزن‌ها و بایاس‌ها، n : تعداد نمونه‌ها و γ : نسبت عملکرد^۲ می‌باشد. علاوه بر آن بخشی از داده‌های آموزش به عنوان داده‌های ارزیابی مقطعی در نظر گرفته شدند که این روش نیز از امکان ایجاد پدیده آموزش بیش از حد شبکه جلوگیری می‌کند.

مدل‌های شبکه عصبی مصنوعی: برای تخمین و پیش‌بینی مقدار محتوای رطبوبتی در هر زمان، از مقادیر محتوای رطبوبتی در زمان‌های قبل از زمان مورد نظر و ترکیب‌های خاصی از آن‌ها استفاده شد. برای این منظور از شبکه عصبی سه لایه با تاخیر زمانی (با یک لایه مخفی) به گونه‌ای استفاده شد که ورودی‌های شبکه را مقادیر رطبوبتی در زمان‌های گذشته و ترکیب‌های خاصی از آن‌ها و خروجی شبکه را پارامتر خاصی که بعداً توضیح داده می‌شود، تشکیل می‌دادند. بنابراین با توجه به تعریف

1- Modified performance function

2- Performance ratio

خاص و رودی‌ها و خروجی شبکه و تعریف خاص تابع خط ا مورد استفاده در الگوریتم پس انتشار خط برای تغییر وزن‌ها و بایاس‌های شبکه، سه نوع شبکه عصبی زمان واقعی با تاخیر زمانی طراحی شد که هر نوع می‌توانست تعداد نرون‌های متغیری در لایه مخفی و ضریب آموزش (η) متغیری را اختیار نماید. لازم به ذکر است که در همه حالت‌ها تابع فعال‌سازی نرون‌های لایه مخفی تابع تائزانت-سیگموید (تائزانت هیپربولیک) و با توجه به محدوده خروجی، تابع فعال‌سازی لایه خروجی (نرون خروجی) خطی در نظر گرفته شد و در همه حالت‌ها از روش آموزش لونبرگ-مارکوارت برای آموزش استفاده گردید. توضیح هر کدام از سه شبکه یاد شده در زیر آمده است.

شبکه عصبی نوع اول: یک شبکه عصبی مصنوعی سه لایه با تاخیر زمانی که چهار مقدار $[Mc(t), Mc(t-1), Mc(t-2), Mc(t-3)]$ را به عنوان ورودی پذیرفته و مقدار $Mc(t) = Mc(t+1) - Mc(t)$ را به عنوان خروجی می‌دهد طراحی و شبیه‌سازی شد. مقدار محتوا رطوبتی در زمان t و $Mc(t+k)$ مقدار محتوا رطوبتی، k زمان بعد از زمان t و $Mc(t-k)$ مقدار محتوا رطوبتی، k زمان قبل از زمان t می‌باشد. علامت روی هر عبارت به معنا متغیر پیش‌بینی شده می‌باشد. این شبکه دارای یک لایه مخفی بوده که تعداد نرون‌های مختلف با ضرایب آموزش متعددی را می‌تواند اختیار کند. به منظور آموزش این شبکه از قانون آموزش پس انتشار خط (BP)^۱ استفاده شد، با این تفاوت که تابع خطابی که در الگوریتم پس انتشار خط برای تغییر وزن‌ها و بایاس‌های شبکه استفاده شد با توجه به خروجی به صورت زیر تعریف شد:

$$e(t) = Mc(t) - Mc(t-1) - \Delta Mc(t) \quad (5)$$

شبکه عصبی نوع دوم: همان‌طور که شکل ۳ نشان می‌دهد این شبکه مانند شبکه نوع اول می‌باشد با این تفاوت که این شبکه مقدار $\tilde{Mc}(t+1)$ را که همان مقدار محتوا رطوبتی پیش‌بینی شده می‌باشد به طور مستقیم در خروجی خود تولید می‌کند و تابع خطابی که در الگوریتم پس انتشار برای تغییر وزن‌ها و بایاس‌ها استفاده می‌شود با توجه به خروجی به صورت زیر تعریف می‌شود:

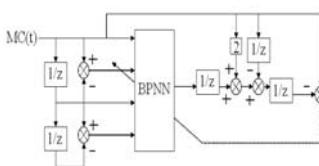
$$e(t) = Mc(t) - \tilde{Mc}(t) \quad (6)$$

1- Back propagation

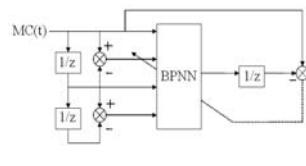
شبکه عصبی نوع سوم: همان طور که شکل ۴ نشان می‌دهد این شبکه نیز مانند دو شبکه قبل می‌باشد با این تفاوت که به منظور افزایش دقت پیش‌بینی، خروجی این شبکه دارای مشتق دوم سیگنال محتوا رطوبتی نیز می‌باشد یعنی خروجی شبکه به صورت $\tilde{M}c(t+2)-2\tilde{M}c(t+1)+Mc(t)$ در نظر گرفته شد که علامت در این عبارت، نشان‌دهنده متغیر پیش‌بینی شده می‌باشد.تابع خطابی که در الگوریتم پس انتشار خطاب برای تغییر وزن‌ها و بایاس‌های این شبکه استفاده شد با توجه به خروجی به صورت زیر تعریف شد:

$$e(t) = \tilde{M}c(t)-2\tilde{M}c(t-1)+Mc(t-2)+2Mc(t-1)-Mc(t-2)+Mc(t) \quad (V)$$

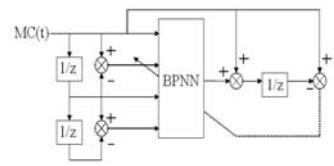
شکل‌های ۲، ۳ و ۴ نحوه به دست آوردن تابع خطاب و استفاده از آن برای آموزش شبکه‌ها به ترتیب برای شبکه عصبی مصنوعی نوع اول، دوم و سوم به صورت نمودار بلوکی نشان می‌دهد. در این شکل‌ها $MC(t)$ مقدار محتوا رطوبتی در زمان t و $\frac{1}{z}$ تاخیر انداز زمانی به اندازه یک واحد زمانی و $BPNN$ نیز شبکه عصبی مصنوعی سه لایه با قانون آموزش پس انتشار خطاب می‌باشد. با تغییر دادن تعداد نرون‌های لایه مخفی از ۵ تا ۲۰ و با در نظر گرفتن ضرایب آموزش مختلف (۵، ۲۰، ۵۰، ۷۵ و ۱۰۰) شبکه‌های متعددی از این نوع تولید شدند ($16 \times 5 = 80$ شبکه عصبی) و هر شبکه بر روی هر یک از ۲۴ وضعیت خشک شدن با استفاده از تابع خطاب ذکر شده و الگوریتم پس انتشار خطاب آموزش داده شد. عملکرد هر شبکه بر روی هر وضعیت خشک شدن با استفاده از ماکریم واریانس و ماکریم ^۱ سنجیده شد. از آن‌جا که ۸۰ شبکه تولید شده بود در نهایت ۸۰ مقدار ماکریم واریانس و ۸۰ مقدار ماکریم RMSE بعدست آمدند و آن شبکه که دارای کمترین این مقادیر بود به عنوان بهترین توپولوژی انتخاب شد. پس از انتخاب بهترین شبکه عملکرد آن در پیش‌بینی بلاذرنگ محتوا رطوبتی در هر یک از ۲۴ وضعیت خشک شدن بررسی شد.



شکل ۴- طرح واره جریان داده در شبکه عصبی نوع سوم و نحوه آموزش آن.



شکل ۳- طرح واره جریان داده در شبکه عصبی نوع دوم و نحوه آموزش آن.



شکل ۲- طرح واره جریان داده در شبکه عصبی نوع اول و نحوه آموزش آن.

نتایج و بحث

دماهی هوای خشک کن بیشترین تأثیر را در فرآیند خشک کردن لایه نازک پسته داشت ($P < 0.01$). این در حالی است که اثر سرعت جريان هوا و رطوبت نسبی هوا در فرآیند خشک کردن ناچیز ارزیابی شد. ضریب پخش موثر براساس دماهی جريان هوا از $10^{-11} \times 10^{-5}$ تا $10^{-10} \times 10^{-9}$ مترمربع بر ثانیه، به صورت متغیر به دست آمد.

نتایج به دست آمده از آموزش و آزمون تست شبکه‌های پیش‌بینی‌کننده نوع اول، دوم و سوم نشان داد که شبکه نوع اول پیش‌بینی بسیار دقیق و شبکه نوع سوم پیش‌بینی قابل قبولی را در مورد محظوهای رطوبتی انجام می‌دهند و این در حالی است که پیش‌بینی شبکه نوع دوم ضعیفتر و غیر دقیق ارزیابی شد. نمودار شکل‌های ۵ تا ۱۰ به ترتیب عملکرد شبکه‌های پیش‌بینی‌کننده نوع اول، دوم و سوم را نشان می‌دهد. برای هر نمودار ۵ منحنی مشاهده می‌شود که هر کدام مربوط به ضرایب آموزش (۵، ۲۰، ۵۰ و ۱۰۰) می‌باشد.

همان‌طورکه در شکل‌های ۵ تا ۷ مشاهده می‌شود کمترین خطای در یک محدوده مشخصی از توپولوژی‌ها اتفاق می‌افتد که در آن محدوده منحنی‌های مربوط به ضرایب آموزش مختلف، هم‌گرا می‌شوند (محدوده مشخص شده در شکل‌ها). محدوده یاد شده برای شبکه‌های نوع اول و سوم در توپولوژی‌های شبکه با ۱۰ تا ۱۲ نرون در لایه مخفی و در شبکه نوع دوم در توپولوژی‌های شبکه با ۲۲ تا ۲۴ نرون در لایه مخفی اتفاق می‌افتد. نکته قابل توجهی که در این نمودارها وجود دارد این است که تا قبل از محدوده هم‌گرا بینی، شبکه‌های آموزش‌یافته با ضریب آموزش پایین‌تر، RMSE کمتر و در نتیجه پیش‌بینی بهتری را ارایه می‌کنند و بعد از این محدوده هم‌گرا بینی شبکه‌های آموزش‌یافته با ضرایب آموزش بیشتر عملکرد بهتری را ارایه می‌کنند. بنابراین برای این‌که از خطای به دست آمده از انتخاب ضرایب آموزش مختلف جلوگیری شود، بهترین شبکه عصبی از هر نوع یاد شده از این محدوده هم‌گرا بینی انتخاب شد.

نتایج به دست آمده از نمودارهای ماکریم واریانس (شکل‌های ۸ تا ۱۰) نیز نتایج به دست آمده از نمودارهای ماکریم RMSE را تصدیق می‌کنند. در این نمودارها نیز کمترین واریانس در یک محدوده مشخصی از توپولوژی‌ها اتفاق می‌افتد که در آن محدوده، منحنی‌های مربوط به ضرایب آموزش مختلف، هم‌گرا می‌شوند. نکته قابل توجه این است که برای هر نوع شبکه عصبی طراحی شده، در هر دو نمودار ماکریم RMSE و ماکریم واریانس، محدوده هم‌گرا بینی ذکر شده در یک محدوده

مشخصی از تعداد نرون‌های لایه مخفی، به‌طور مشترک اتفاق می‌افتد. بنابراین به‌طور کلی می‌توان نتیجه گرفت که شبکه‌های عصبی نوع اول و سوم بهترین عملکرد پیش‌بینی خود را در توپولوژی‌های با ۱۰ تا ۱۲ نرون در لایه مخفی، و شبکه عصبی نوع دوم بهترین عملکرد پیش‌بینی خود را در توپولوژی‌های با ۲۲ تا ۲۴ نرون در لایه مخفی ارایه می‌کنند.

نمودار شکل ۱۱ منحنی‌های خطای پیش‌بینی بلادرنگ محتوا رطوبتی در یکی از وضعیت‌های خشک شدن (دما هوای خشک‌کن ۵۵ درجه سانتی‌گراد، سرعت جریان هوا ۱ متر بر ثانیه و رطوبت نسبی هوا ۵ درصد) را برای شبکه عصبی نوع اول، با ۱۱ نرون در لایه مخفی، شبکه عصبی نوع دوم با ۲۳ نرون در لایه مخفی و شبکه عصبی نوع سوم با ۱۱ نرون در لایه مخفی، به عنوان نمونه نشان می‌دهد. همان‌طور که از این نمودار بر می‌آید شبکه عصبی نوع اول با دقت بسیار بالایی در تمامی زمان‌های خشک شدن می‌تواند سیگنال محتوا رطوبتی را به صورت بلادرنگ به سرعت یاد گرفته و پیش‌بینی کند. شبکه عصبی نوع سوم نیز پیش‌بینی قابل قبولی را ارایه می‌کند با این تفاوت که نوسانات سیگنال خطای در این نوع شبکه، زیاد می‌باشد. در ضمن شبکه نوع سوم محتوا رطوبتی در زمان‌های ابتدایی فرایند خشک شدن را با دقت پایین‌تری نسبت به زمان‌های بعدی تخمین می‌زند یعنی دیرتر از شبکه نوع اول روند سیگنال محتوا رطوبتی را به صورت بلادرنگ یاد می‌گیرد. همان‌طور که از نمودار شکل ۱۱ مشاهده می‌شود شبکه عصبی نوع دوم عملکرد ضعیف‌تری را نسبت به شبکه‌های عصبی نوع اول و سوم از خود نشان می‌دهد. میزان خطای پیش‌بینی در شبکه نوع دوم، زیاد بوده و غیر از محدوده کوچک و مشخصی از ابتدا فرایند خشک شدن، تقریباً در تمام زمان‌های خشک شدن این مقدار خطای ثابت می‌باشد.

پس از بررسی دقت پیش‌بینی کننده‌های بلادرنگ طراحی شده و تعیین برتری شبکه نوع اول نسبت به بقیه، شکل ۱۲ پیش‌بینی بلادرنگ سیگنال محتوا رطوبتی پسته در طول فرایند خشک شدن توسط شبکه نوع اول را نشان می‌دهد. همان‌طور که در شکل ۱۲ دیده می‌شود دقت پیش‌بینی این نوع پیش‌بینی کننده بسیار بالا می‌باشد به‌طوری‌که نمودارهای محتوا رطوبتی واقعی و پیش‌بینی شده کاملاً بر هم منطبق شده‌اند.

کاشانی نژاد و همکاران [۸] سیستمیک فرایند خشک کردن پسته (رقم اوحدی) را مورد مطالعه قرار دادند و مدل پیج را به عنوان بهترین مدل برآذش کننده محتوا رطوبتی با کمترین خطای معرفی کردند. ایشان ضرایب مربوط به مدل پیج را برای هر کدام از وضعیت‌های خشک کردن به دست آورده و به منظور ارایه یک مدل مشخص و ثابت از ضرایب به دست آمده رگرسیون‌گیری کردند. در نهایت

ایشان یک مدل پیچ با ضرایب مشخص که هر کدام تابعی از دما و سرعت هوا بودند، به دست آورند که در آن، مقدار R^2 برای ضرایب N, k در مدل پیچ طبق معادله (۵) به ترتیب 0.73 و 0.81 گزارش شده است.

$$MR = \frac{M - M_e}{M_0 - M_e} = \exp(-kt^N) \quad (8)$$

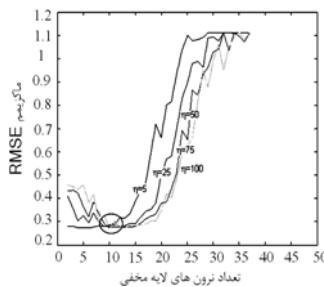
مدلی که ایشان ارایه کردند صرفاً برای تقریب‌زنی محتوا رطوبتی در زمان‌های مربوط به محدوده داده‌برداری می‌باشد در حالی که مدل شبکه عصبی ارایه شده در این پژوهش علاوه‌بر این که یک مدل واحد و قابل استفاده برای تمامی وضعیت‌های خشک کردن می‌باشد، به پیش‌بینی محتوا رطوبتی با استفاده از محتواهای رطوبتی زمان‌های قبل (در حوزه محتوا رطوبتی و نه در حوزه زمان) با دقت بالا و با R^2 و ماقزیموم واریانس خطأ در تمامی وضعیت‌های خشک کردن، به ترتیب برابر با 0.97 ، 0.97 و 0.97 می‌پردازد. از دیگر برتری‌های این شبکه به دست آمده، قابلیت یادگیری فرآیند در همان زمانی است که فرآیند رخ می‌دهد و به همین دلیل می‌تواند به مرور زمان دقت پیش‌بینی خود را در طول فرآیند افزایش دهد.

به طور کلی می‌توان نتیجه گرفت که شبکه‌های عصبی نوع اول و سوم عملکرد بسیار بهتری را در پیش‌بینی بلاذرنگ سیگنال محتوا رطوبتی، نسبت به شبکه‌های عصبی نوع دوم، از خود نشان می‌دهند و این در حالی است که در این میان، عملکرد شبکه‌های نوع اول از شبکه‌های نوع سوم نیز بهتر تشخیص داده شد.

نتیجه‌گیری

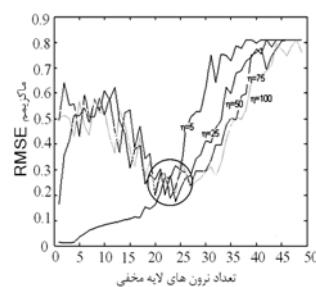
در این پژوهش چند شبکه عصبی سه لایه با تاخیر زمانی (با یک لایه مخفی) با الگوریتم آموزش پس انتشار خطأ و خروجی‌های متفاوت و توابع خطأ متفاوت مورد استفاده در آموزش شبکه‌ها تعریف شد و عملکرد آن‌ها در پیش‌بینی مقدار محتوا رطوبتی در هر زمان براساس مقادیر محتوا رطوبتی در زمان‌های قبلی و ترکیب‌های خاصی از آن‌ها، در تمامی وضعیت‌های خشک شدن بررسی شد. بنابراین سه نوع شبکه در نظر گرفته شد که نتایج به دست آمده، بیانگر عملکرد بسیار خوب نوع اول، عملکرد به نسبت قابل قبول نوع سوم و عملکرد ضعیف‌تر نوع دوم داشت.

از نتایج به دست آمده از این پژوهش می‌توان در پیش‌بینی هوشمند و بلادرنگ مقدار محتوا رطوبتی در هر زمان براساس محتواهای رطوبتی زمان‌های قبل و ترکیب‌های خاصی از آن‌ها (بدون استفاده از اندازه‌گیری متغیرهای عملیاتی) و تنها با داشتن اطلاعات مربوط به محتوا رطوبتی نقاط ابتدایی از فرایند خشک شدن و نیز در کنترل غیرخطی فرآیند خشک شدن استفاده نمود. از برتری‌های دیگر این پیش‌بینی‌کننده امکان پیش‌بینی محتوا رطوبتی در خارج از محدوده داده‌برداری می‌باشد در حالی که روش‌های رگرسیون‌گیری و تقریب‌زنی توابع، فقط در محدوده داده‌برداری صادق می‌باشند.



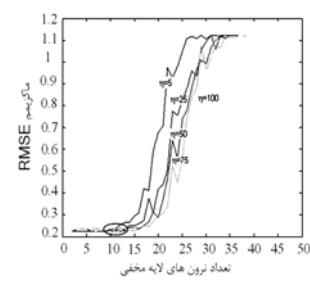
شکل ۷- میانگین متوسط خطاهای

به دست آمده از پیش‌بینی محتوا رطوبتی
با استفاده از شبکه‌های مختلف
از نوع سوم.



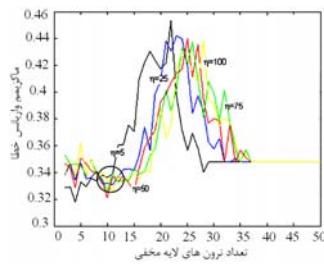
شکل ۶- میانگین متوسط خطاهای

به دست آمده از پیش‌بینی محتوا رطوبتی
با استفاده از شبکه‌های مختلف
از نوع دوم.

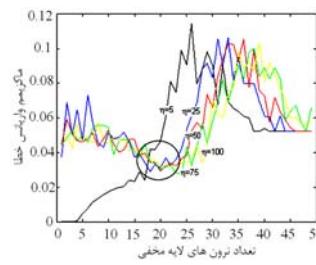


شکل ۵- میانگین متوسط خطاهای

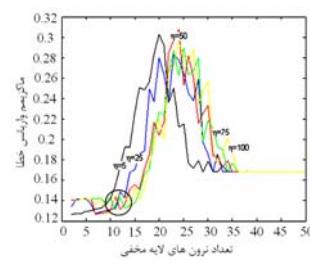
به دست آمده از پیش‌بینی محتوا رطوبتی
با استفاده از شبکه‌های مختلف
از نوع اول.



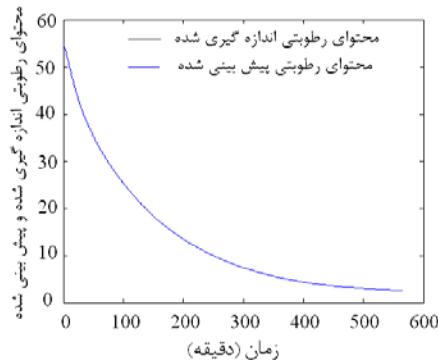
شکل ۱۰- میانگین واریانس خطاهای
به دست آمده از پیش‌بینی محتوا رطوبتی
با استفاده از شبکه‌های مختلف
از نوع سوم.



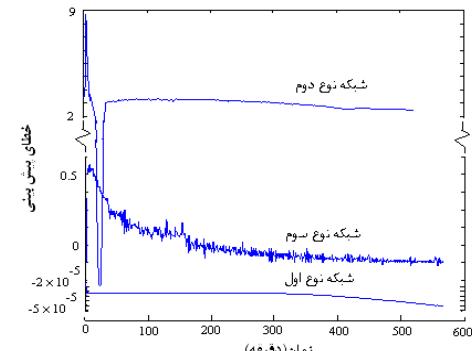
شکل ۹- میانگین واریانس خطاهای
به دست آمده از پیش‌بینی محتوا رطوبتی
با استفاده از شبکه‌های مختلف
از نوع دوم.



شکل ۸- میانگین واریانس خطاهای
به دست آمده از پیش‌بینی محتوا
رطوبتی با استفاده از شبکه‌های
مختلف از نوع اول.



شکل ۱۲- پیش‌بینی محتوا رطوبتی توسط شبکه نوع اول.



شکل ۱۱- خطا پیش‌بینی محتوا رطوبتی.

منابع

- 1.Basheer, L.A., and Hajmeer, M. 2000. Artificial neural networks: Fundamentals, computing, design and application. *Journal of Microbiological Methods*, 43, 3-31.
- 2.Cohen, J.S., and Yang, T.C.S. 1995. Progress in food dehydration. *Trends in Food Science and Technology*, 6, 20-25.
- 3.Davidson, V.J., Li, X., and Brown, R.B. 2002. Fuzzy methods for ginseng drying control. *The 9th International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*, 1–5, July, Annecy, France, 913-918.
- 4.Erenturk, S., and Erenturk, K. 2006. Comparison of genetic algorithm and neural network approaches for the drying process of carrot. *Journal of Food Engineering*, 78, 905-912.
- 5.Hernandez-Perez, J.A., Garcya-Alvarado, M.A., Trystram, G., and Heyd, B. 2004. Neural networks for the heat and mass transfer prediction during drying of cassava and mango. *Innovative Food Science and Emerging Technologies*, 5, 57-64.
- 6.Kaminski, W., Strumillo, P., and Tomczak, E. 1998. Neurocomputing approaches to modelling of drying process dynamics. *Drying Technology*, 16, 967-992.
- 7.Karathanos, V.T., and Belessiotis, V.G. 1999. Application of a thin layer equation to drying data fresh and semi-dried fruits. *Journal of Agricultural Engineering Research*, 74, 355-361.
- 8.Kashaninejad, M., Mortazavi, A., Safekordi, A., and Tabil, L.G. 2007. Thin-layer drying characteristics and modeling of pistachio nuts. *Journal of Food Engineering*, 78, 98-108.
- 9.Kosko, B. 1992. Neural Networks and Fuzzy Systems. *A Dynamical Systems Approach to Machine Intelligence*, Prentice-Hall Inc., Upper Saddle River, NJ, USA.
- 10.Li, X. 2002. Improved ginseng drying with three-stage temperature control. M.Sc. Thesis, University of Guelph, Canada.

- 11.Li, Y.R., and Morey, R.V. 1987. Thin-layer drying rates and quality of cultivated American ginseng. *Transactions ASAE*, 30 (3), 842-847.
- 12.Martynenko, A.I., and Yang Simon, X. 2006. Biologically Inspired Neural Computation for Ginseng Drying Rate. *Biosystems Engineering*, 95 (3), 385-396.
- 13.Midilli, A., and Kucuk, H. 2003. Mathematical modeling of thin layer drying of pistachio by using solar energy. *Energy Conversion and Management*, 44 (7), 1111-1122.
- 14.Mujumdar, A., and Turner, I. 1997. Mathematical Modelling and Numerical Techniques in Drying Technology. Marcel Dekker, New York, USA.
- 15.Ochoa-Martinez, C.I., and Ayala-Aponte, A.A. 2007. Prediction of mass transfer kinetics during osmotic dehydration of apples using neural networks. *LWT*, 40, 638-645.
- 16.Pathak, P.K., Agrawal, Y.C., and Singh, B.P.N. 1991. Thin layer drying model for rapeseed. *Transactions of the ASAE*, 34 (6), 2505-2508.
- 17.Rai, P., Majumdar, G.C., Dasgupta, S., and De, S. 2005. Prediction of the viscosity of clarified fruit juice using artificial neural network: A combined effect of concentration and temperature. *Journal of Food Engineering*, 68, 527-533.
- 18.Razavi, S.M.A., Emamzadeh, B., Rafe, A., and Mohammad Amini, A. 2007. The physical properties of pistachio nut and its kernel as a function of moisture content and variety: part I. Geometrical properties, *Journal of Food Engineering*, 81, 209-217.
- 19.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 (6), 617-623.
- 20.Techasena, O., Lebert, A., and Bimbenet, J.J. 1992. Simulation of deep bed drying of carrots. *Journal of Food Engineering*, 16, 267-281.
- 21.Trelea, I.C., Courtois, F., and Trystram, G. 1997a. Dynamic models for drying and wet-milling quality degradation of corn using neural networks. *Drying Technology*, 15 (3 and 4), 1095-1102.



Intelligent Real Time Prediction of Moisture Content using Artificial Neural Network in Pistachio Thin Layer Drying

S. Hosseinpour¹, *Sh. Rafiee² and M. Kashaninejad³

¹Ph.D. Student, Dept. of Mechanical Engineering of Agricultural Machinery, University of Tehran, ²Associate Prof., Dept. of Mechanical Engineering of Agricultural Machinery, University of Tehran, ³Associate Prof., Dept. of Food Science, Gorgan University of Agricultural Sciences and Natural Resources

Received: 2011-01; Accepted: 2011-06

Abstract

In this paper, real time prediction of pistachio nuts moisture content (MC) during drying, based on previous moisture contents using artificial neural network have been studied. In order to obtain experimental data, thin layer drying experiments were conducted at four air temperatures (25, 40, 55, 70°C), three air velocities (0.5, 1 and 1.5 m/s) and two relative humidities (5, 20%). Moisture contents of pistachio nuts (Ohadi variety) were measured during drying in these conditions. The drying air temperature had the greatest effect and air velocity and relative humidity had a small effect on the drying kinetics of pistachio nuts. Effective diffusivity of water varied from 5.42×10^{-11} to $9.29 \times 10^{-10} \text{ m}^2/\text{s}$ over the temperature range studied. Moisture content signals were considered as time series to predict MC based on special combinations of previous times MCs using three modified neural networks. The neural network with the best performance to predict MCs, which has 11 neurons in the hidden layer for every learning rate, was obtained. The best obtained neural network can be trained during drying in real time. Maximum root of mean squared error (RMSE) 0.23 and maximum variance of prediction errors 0.13 were obtained. This neural network can predict the moisture content of fourth point in drying process based on three previous points and when the process reaches to the predicted point and the real value of moisture content is measured, the difference between predicted and real value is calculated and according to the neural network structure and its output and the defined error function the neural network is trained and the training process will be continued as mentioned above until the drying process will finish. The results show that the obtained neural network is a very good predictor that learns the process of drying and its parameter will be approximately fixed after a few times the process begins. The derived predictor can predict moisture contents with high accuracy except at a few primary times of drying process in which the predictor is trained and no control is applied to the drying process. The predictor can be used either as a part of nonlinear real time control systems or as a differentiator of MCs signal.

Keywords: Pistachio; Moisture content; Predictor; Real time; Artificial neural network

* Corresponding Author; Email: shahinrafiee@ut.ac.ir