



مقایسه مدل‌های رگرسیونی با شبکه عصبی در پیش بینی خواص کیفی سیب با پوشش

خوراکی

محمد هادی موحدنژاد^{۱*}، محمد هادی خوش تقاضا^۲، سعید مینایی^۳، محمد جلال الدین ظهوریان مهر^۳

۱- استادیار مکانیک بیوسیستم (گروه آب و خاک) دانشکده کشاورزی دانشگاه صنعتی شاهرود

۲- دانشیار گروه مکانیک ماشین‌های کشاورزی دانشکده کشاورزی دانشگاه تربیت مدرس

۳- دانشیار گروه رنگ، رزین و پوشش‌های سطح پژوهشکده فرایند پژوهشگاه پلیمر و پتروشیمی ایران

* ایمیل نویسنده مسئول: mhmovahed@yahoo.com

چکیده

به دلیل تولید بالای سیب در ایران و ضایعات نسبتاً بالا، استفاده از روش‌های بهبود دهنده برای نگهداری آن ضرورت دارد. یکی از روش‌های مناسب به کارگیری پوشش‌های خوراکی نانوکامپوزیت‌ها با پایه‌ی گیاهی می‌باشد. هدف تعیین مدل مناسبی برای پیش‌بینی تغییرات خواص کیفی سیب بر اساس شرایط و زمان انبارداری و نوع پوشش می‌باشد. در این راستا سیب زرد دماوند (گلدن دلشیز) برای آزمایش‌ها انتخاب شد. بعد از پوشش دهی، نمونه‌های سیب در دو شرایط محیطی (20°C و رطوبت ۳۰٪) و سردخانه-ای (3°C و رطوبت رطوبت ۹۵٪) به مدت شش ماه نگهداری شد. خواص کیفی (pH، میزان مواد جامد محلول) در طی انبارداری بررسی شد. همچنین مدل‌سازی خواص بر اساس داده‌های مستخرج از آزمایش‌ها توسط رگرسیون و شبکه عصبی انجام پذیرفت. در خواص کیفی مدل رگرسیون برای میزان مواد جامد محلول جواب نداده و در pH نیز فقط در شرایط محیطی مناسب بود. بهترین مقدار R^2 در pH برای مدل ترکیبی ۸۴/۹٪ شد. الگوریتم trainbr بهترین عملکرد را داشت. با توجه به مقدار خطا بهترین توپولوژی در تابع tansig ۸-۱۰-۶ و در تابع logsig با همان توپولوژی انتخاب شد. مقادیر MSE و R برای این دو مدل به ترتیب ۰/۰۰۶۶ و ۹۲/۱ بدست آمد.

واژه‌های کلیدی: پوشش خوراکی، خواص کیفی، شبکه عصبی، مدل رگرسیونی غیر خطی

مقدمه

یکی از مهمترین نکات جهت کاهش ضایعات محصولات باغی توجه به عوامل پس از برداشت، منجمله انبارداری می‌باشد. در این زمینه عوامل متعددی در نگهداری بهینه محصولات باغی موثر می‌باشند. از آن جمله می‌توان به دما، رطوبت، فشار اتمسفر، نوع پوشش دهی و بسته‌بندی اشاره نمود (Anonymous, 2009).

از روشهای متداول در حفاظت میوه‌ها استفاده از پوششهای خوراکی بوده است. از مزایای پوششهای خوراکی، کنترل انتقال اکسیژن، دی اکسید کربن و رطوبت می‌باشد (Embuscado and Huber, 2009).

هدف استفاده از شبکه عصبی مدل‌های رگرسیونی غیرخطی، تعیین مدل مناسب برای خواص کیفی، در طی انبارمانی با شرایط مختلف نگهداری و با پوشش‌های مختلف بود. در نهایت این دو روش با هم مقایسه شده تا روش مناسب‌تر تعیین شود.

شبکه عصبی یکی از روشهای مناسب برای مدل سازی و پیش‌بینی خواص محصولات کشاورزی می‌باشد. در تحقیق از شبکه عصبی برای پیش‌بینی خواص کیفی سیب به منظور طبقه بندی استفاده شده و نتایج خوبی بدست آمد (Bhatt et al., 2014). در پژوهش دیگر با استفاده از دید ماشین و شبکه عصبی درجه بندی اتومات سیب بر اساس خواص کیفی و فیزیکی انجام گرفت. در این تحقیق شبکه مورد استفاده شبکه چند لایه‌ی پرسپترون (MLP) با الگوریتم پس انتشار پیشخور (FFBP) می‌باشد و خطای طبقه بندی بسیار پایین بود (Bhatt and pant, 2015).

در مقاله‌ای از شبکه عصبی برای پیش بینی قهوه‌ای شدن سیب در اثر صدمات فیزیکی بررسی گردید. در این تحقیق دو الگوریتم BB¹ و BDLRF² با یکدیگر مقایسه شد و روش BDLRF عملکرد بهتری از خود نشان داد (Zarifneshat et al., 2011).

مواد و روش‌ها

تهیه نمونه و روش انبارداری

در اوایل ماه آبان سیب گلدن دلینز از باغی در دماوند تهیه شد. در ابتدا نمونه‌ها قبل از آماده‌سازی پوششها و پوشش دهی در دمای ۳°C و رطوبت ۹۰٪ نگهداری شد. انبارداری سیب در دو شرایط انبارداری، سردخانه در دمای پایین ۲ تا ۴ درجه سلسیوس و با رطوبت ۹۵ درصد و شرایط محیطی در دمای حدود ۲۰ تا ۲۵ با رطوبت حدود ۴۰ تا ۵۰ درصد انجام شد. نمونه‌گیری در ۶ دوره زمانی به صورت ماهانه انجام شده و آزمایشات روی آنها صورت گرفت. در هر ماه خواص سیب (شدت رنگ، بریکس، چگالی و pH) مورد ارزیابی قرار گرفته شد.

تهیه پوششها و پوشش دهی

¹ Basic Backpropagation

² Backpropagation with Declining Learning Rate Factor



سه پوشش در این تحقیق استفاده گردید. اولین پوشش واکس خوراکی با پایه کارنوبا بود. این واکس دارای برند تجاری بوده و ساخت شرکت بین المللی زتا فرانسه می باشد. پوشش کیتوسان و نانو کامپوزیت کیتوسان-رس در آزمایشگاه تولید شد. کیتوسان مورد استفاده دارای وزن ملکولی پایین با درجه دی استیلیشن^۱ ۸۵٪ (شرکت Sigma-Aldrich) می باشد. خاک رس مورد استفاده از نوع بنتونیت بوده که از شرکت خاک سفید علی گودرز تهیه گردید.

خواص کیفی اندازه گیری شده

در این مرحله میزان مواد جامد محلول (میزان مواد جامد محلول^۲) و pH اندازه گیری می شود. این دو خاصیت پارامترهای مناسبی برای تعیین مزه و کیفیت محصولات کشاورزی می باشد. میزان مواد جامد محلول رابطه مستقیم با قند محصولات داشته و pH نیز میزان اسیدی بودن میوه را تعیین می کند.

برای اندازه گیری pH از دستگاه pH meter مدل Metrohm ساخت کشور سوئیس استفاده شد. برای تعیین آن، توسط دستگاه آبمیوه گیری عصاره پنج عدد سیب گرفته و pH آنها تعیین گردید.

برای بدست آوردن میزان مواد جامد محلول (TSS^۳) با دستگاه رفرکتومتر ساخت شرکت ATAGO ژاپن مدل dr-a1 استفاده شد. در این مرحله یک قطره از عصاره استخراج شده با سرنگ روی شیشه دستگاه ریخته و با تنظیم چشمی میزان مواد جامد محلول تعیین گردید.

مدل سازی با شبکه عصبی

برای مدل سازی آزمایشها با استفاده از شبکه عصبی از نرم افزار MATLAB استفاده شد. داده ها در ابتدا در یک ماتریس وارد شده و سپس به شبکه فراخوان شد. سپس داده ها به دو صورت ورودی و خروجی تقسیم گردید. ورودی ها شامل زمان نگهداری، نوع پوشش، درخت، روش نگهداری و پارامترهای فیزیکی نمونه (وزن، حجم و اقطار) بوده و داده های خروجی نیز شامل داده های استخراجی از آزمایشات فیزیکی (شدت رنگ، افت وزن و چگالی) بودند. داده های هر دسته به طور تصادفی به سه قسمت، ۸۰٪، ۱۰٪ و ۱۰٪ تقسیم گردید. قسمت اول برای یادگیری، قسمت دوم و سوم نیز برای ارزیابی و آزمون مدل تعیین گردید. در ادامه داده ها برای شبکه نرمال سازی شد. معادلات نرمال سازی، تمام داده ها را بین صفر و یک قرار می دهد. همچنین برای خروج داده ها از حالت نرمال به حالت اصلی از معادله دی نرمال کردن استفاده گردید (Demuth and Beale, 2009).

شبکه مورد استفاده شبکه چند لایه ی پرسپترون (MLP) با الگوریتم پس انتشار پیشخور (FFBP) می باشد. برای آموزش داده ها در فضای نرم افزار برنامه ای نوشته شد. برای بهینه سازی مدل، چهار المان بررسی گردید. این المانها شامل الگوریتم یادگیری، تابع

¹ degree of deacetylation

² Brix

³ Total Soluble Solid

آستانه، تعداد لایه‌های پنهان و تعداد نورن‌های لایه‌های پنهان بودند. الگوریتم‌های یادگیری انواعی چون الگوریتم لوبنرگ-مارکواریت (LM)، پس انتشار بازگشتی (RP)، و الگوریتم‌های دیگر دارد. توابع آستانه مورد استفاده در مدل‌سازی سه تابع خطی، تانژانت هایپربولیک سیگموئید و سیگموئید لگاریتمی بودند (Demuth and Beale, 2009).

لایه‌های پنهان به چهارصورت تک لایه‌ای، دو لایه‌ای و سه لایه‌ای و چهار لایه‌ای بررسی شد. تعداد نورن نیز در یک پیش آزمایش از ۲ تا ۱۰۰ نورن بررسی گردید. پس از آن محدوده‌ی مناسب تعیین می‌گردد. تعداد ۱۷ الگوریتم‌های یادگیری در یک پیش آزمایش بررسی و سپس الگوریتم‌های مناسب‌تر انتخاب می‌گردد. سپس با برنامه نوشته شده چهار المان تعداد لایه، تعداد نورن، الگوریتم آموزش، تابع آستانه بررسی شده و برای تمام ترکیب‌های ایجاد شده بر اساس چهار المان خطا و بقیه پارامترهای ارزیابی تعیین می‌گردد. بر اساس کمترین میانگین مربعات خطا (MSE) بهترین مدل برای هر دسته آزمایش بدست آمد. پارامترهای ارزیابی دیگر شامل ضریب همبستگی (r) می‌باشد (Demuth and Beale, 2009).

بهترین نتایج برای هر دسته‌ی آزمایشی برای الگوریتم‌های منتخب و سه تابع آستانه در دو ترکیب تعداد لایه و تعداد نورن در جدولی ارائه شد. همچنین در برنامه نوشته شده R^2 داده‌های خروجی پیش‌بینی شده توسط شبکه نسبت به داده‌های خروجی واقعی نیز بدست می‌آید. این اطلاعات نیز برای حالات بهینه ارائه گردید.

مدل رگرسیون غیر خطی

در این مرحله بر اساس داده‌های بدست آمده و با استفاده از نرم افزار Datafit و SPSS، مدل رگرسیونی مناسب برای خواص محصول در طی زمان انبارداری و برای سه پوشش با نمونه شاهد و در دو شرایط نگهداری که در کل هشت حالت بوده، بدست آمد. مدل انتخاب شده بر اساس R^2 مناسب (حداقل ۷۵٪) و سادگی مدل تعیین می‌شود. برخی از توابع مورد استفاده در جدول (۱) آمده است. همچنین برای ارائه‌ی مدل در مورد تغییرات خواص محصول نسبت به شرایط محیطی، مدت زمان نگهداری و پوشش خوراکی از شبکه‌های عصبی نیز استفاده گردید. علت مدل‌سازی پیدا کردن مدلی مناسب برای پیش‌بینی حالتهایی بوده که در مورد آن آزمایش صورت نگرفته است. همچنین این مدل‌ها کاربرد مناسبی برای انتخاب شرایط نگهداری سیب با بوده، که با داشتن اطلاعات اولیه از نمونه و با مدل شرایط بهینه انتخاب می‌شود.

جدول ۱: برخی از توابع رگرسیون غیرخطی مختلف (anonymous, 2002)

تابع	مدل	شماره مدل
$Y(t)=a_1+a_2 \times t$	خطی (Linear)	۱
$Y(t)=a_1+a_2 \times \ln(t)$	لگاریتمی (Logarithmic)	۲
$Y(t)=a_1+a_2/t$	معکوس (Inverse)	۳
$Y(t)=a_1+a_2 \times t+a_3 \times t^2$	درجه دو (Quadratic)	۴
$Y(t)=a_1+a_2 \times t+a_3 \times t^2+a_4 \times t^3$	درجه سه (Cubic)	۵
$Y(t)=a_1 \times a_2^t$	ترکیبی (Compound)	۶
$Y(t)=a_1 \times t^{a_2}$	توانی (Power)	۷



$Y(t)=\exp(a_1+a_2/t)$	نمایی معکوس (S)	۸
------------------------	-----------------	---

نتایج و بحث

مدل رگرسیونی غیر خطی

pH

در جدول (۲) نتایج بهترین مدل رگرسیونی برای هشت حالت ترکیبی از پوشش و شرایط نگهداری ارائه شد. در مدل سازی pH در طی زمان شرایط محیطی بهتر جواب داد. بهترین R^2 با مقدار ۸۴/۹٪ با تابع توانی در شرایط محیطی روی نمونه بدون پوشش رخ داد.

جدول ۲: مدل رگرسیونی برای pH

MSE	R^2	ضرایب			تابع	مدل	پوشش	روش نگهداری
		a_3	a_2	a_1				
۰/۰۰۱	۰/۸۴۹		۰/۱۰۰	۴/۱۸۳	$pH(t)=a_1 \times t^{a_2}$	Power	بدون پوشش	محیطی
۰/۰۰۱	۰/۷۸۷		۰/۰۷۳	۴/۱۷۶	$pH(t)=a_1 \times t^{a_2}$	Power	واکس	محیطی
۰/۰۱	۰/۸۳۵	-۰/۰۳۴	۰/۳۵۷	۳/۸۵۸	$pH(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	کیتوسان	محیطی
۰/۰۰۱	۰/۸۱۳		-۰/۱۶۴	۱/۵۹۲	$pH(t)=e^{(a_1+a_2/t)}$	S	نانو کامپوزیت	محیطی
۰/۰۱۸	۰/۴۹۷	-۰/۰۱۸	۰/۲۰۰	۴/۰۰۳	$pH(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	بدون پوشش	سردخانه‌ای
۰/۰۲۲	۰/۲۰۷	-۰/۰۰۷	۰/۰۸۹	۴/۰۵۳	$pH(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	واکس	سردخانه‌ای
۰/۰۲۶	۰/۴۲۲	-۰/۰۱۰	۰/۱۴۸	۳/۹۵۸	$pH(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	کیتوسان	سردخانه‌ای
۰/۰۲۸	۰/۳۲۱	-۰/۰۰۵	۰/۰۹۳	۴/۰۱۸	$pH(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	نانو کامپوزیت	سردخانه‌ای

pH = زمان (s)

بریکس

بهترین مدل رگرسیون تغییرات میزان مواد جامد محلول در جدول (۳) برای هشت حالت ترکیبی از پوشش و شرایط نگهداری ارائه شده است. با بررسی R^2 در مدل‌های مختلف، بالاترین مقدار ۷۵/۰٪ برای تابع درجه دو برای پوشش کیتوسان و شرایط محیطی بدست آمد. با توجه به نتایج دیگر حالتها در کل می‌توان نتیجه گرفت که مدل رگرسیونی برای پیش‌بینی روند میزان مواد جامد محلول مناسب نیست.

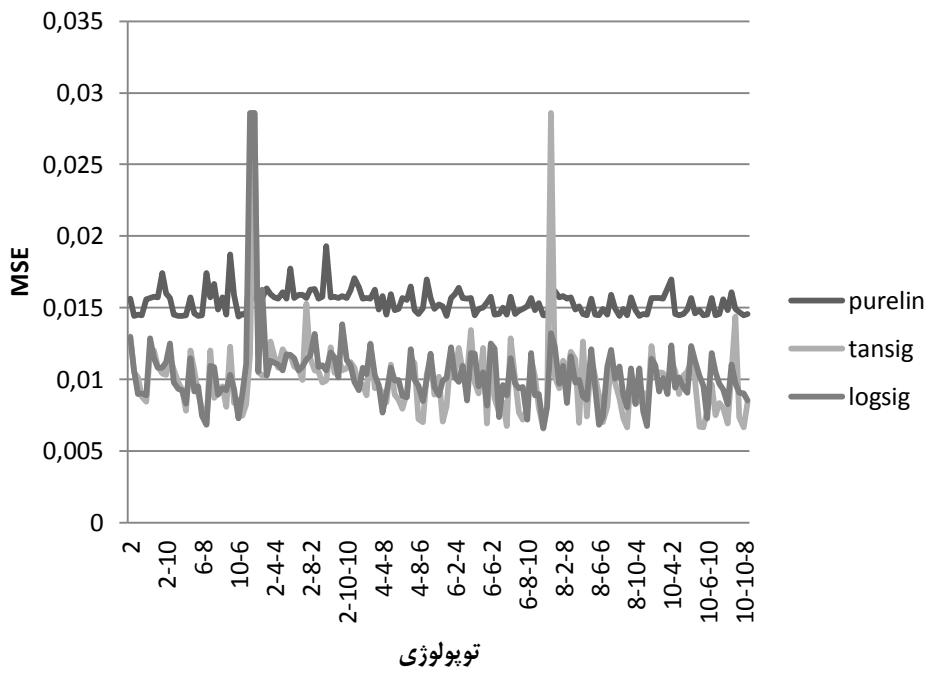
جدول ۳: مدل رگرسیونی برای میزان مواد جامد محلول

MSE	R ²	ضرایب			تابع	مدل	پوشش	روش	نگهداری
		a ₃	a ₂	a ₁					
۳۴,۰۶	۰,۲۵۹	۰,۱۲۴	-۰,۳۲۵	۱۲,۹۹۷	$brix(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	بدون پوشش	محیطی	
۲,۰۱	۰,۳۲۸		-۰,۲۳۹	۲,۷۲۳	$brix(t)=e^{(a_1+a_2/t)}$	S	واکس	محیطی	
۲,۶۵	۰,۷۵۰	۰,۱۱۰	۰,۴۲۴	۱۱,۹۳۳	$brix(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	کیتوسان	محیطی	
۴,۳۱	۰,۳۸۹	۰,۳۱۶	-۱,۵۴۳	۱۴,۳۵۴	$brix(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	نانو کامپوزیت	محیطی	
۱,۵۰	۰,۰۶۹	-۰,۱۲۷	۰,۹۰۴	۱۱,۳۷۹	$brix(t)=a_1+a_2 \times t+a_3 \times t^2$	Quadratic	بدون پوشش	سردخانه‌ای	
۱,۴۳	۰,۰۴۷		-۰,۰۷۷	۲,۵۹۸	$brix(t)=e^{(a_1+a_2/t)}$	S	واکس	سردخانه‌ای	
۰,۲۲	۰,۲۴۸		-۰,۱۷۹	۲,۶۷۷	$brix(t)=e^{(a_1+a_2/t)}$	S	کیتوسان	سردخانه‌ای	
۱,۱۵	۰,۲۰۴		-۰,۱۴۳	۲,۶۲۷	$brix(t)=e^{(a_1+a_2/t)}$	S	نانو کامپوزیت	سردخانه‌ای	

brix = میزان مواد جامد محلول t = زمان (s)

شبکه عصبی

در خواص کیفی ورودی‌های شبکه شامل وزن، حجم، اقطار سه گانه، شرایط نگهداری، نوع پوشش، زمان و درخت بوده و داده‌های خروجی به ترتیب شامل میزان مواد جامد محلول، pH می‌باشد. بر اساس مقدار MSE توابع tansig, logsig عملکرد بهتری نسبت به تابع خطی دارد (شکل ۱). الگوریتم trainbr بهترین عملکرد را داشت. با توجه به مقدار خطا بهترین توپولوژی در تابع tansig ۸-۱۰-۶ و در تابع logsig با همان توپولوژی انتخاب شد. مقادیر MSE و R برای این دو مدل به ترتیب ۰/۰۰۶۶ و ۹۲/۱ بدست آمد (جدول ۴).



شکل ۱: مقادیر MSE برای الگوریتم BR در توپولوژی‌های مختلف برای خواص کیفی

جدول ۴: پارامترهای ارزیابی برای مدل‌های بهینه در توابع آستانه و الگوریتم آموزش برای خواص کیفی

پارامترهای آموزش							روش آزمون		
Epoch	MSE				R	MSE	روش آزمون		
	آزمون	ارزیابی	آموزش	آموزش			تابع	نورن	آموزش
	۱۷	۰,۰۱۵۰	۰,۰۱۲۹	۰,۰۱۴۵			۰,۸۱۷۹	۰,۰۱۴۴	۱۰-۸-۱۰
۲۹	۰,۰۰۷۴	۰,۰۱۱۵	۰,۰۰۵۸	۰,۹۱۲۶	۰,۰۰۷۳	۱۰-۱۰	Tansig	Trainlm	
۳۵	۰,۰۰۹۶	۰,۰۱۰۳	۰,۰۰۵۳	۰,۹۱۶۹	۰,۰۰۶۹	۱۰-۶-۱۰	Logsig		
۱۰۰	۰,۰۰۱۶	۰,۰۰۱۵	۰,۰۱۱۳	۰,۸۱۷۸	۰,۰۱۴۴	۱۰-۶	Purelin		
۴۷	۰,۰۰۰۷	۰,۰۰۱۰	۰,۰۰۴۱	۰,۹۲۱۶	۰,۰۰۶۶	۶-۱۰-۸	Tansig	trainbr	
۵۶	۰,۰۰۰۹	۰,۰۰۰۸	۰,۰۰۴۵	۰,۹۲۱۲	۰,۰۰۶۶	۶-۱۰-۸	Logsig		

با توجه به نتایج جدول (۵) به صورت جداگانه برای هر یک از خواص به صورت فوق بدست آمد. در تابع tansig و الگوریتم
pH trainlm با R^2 ۰.۸۱ و بریکس با تابع logsig الگوریتم trainbr و R^2 ۰.۷۰ بهترین حالت بود.

جدول ۵: ضریب تعیین مدل‌های بهینه در توابع آستانه و الگوریتم آموزش برای خواص کیفی

ضریب تعیین (R^2)		روش آزمون		
pH	میزان مواد جامد محلول	روشن		
		نورن	تابع	آموزش
۰.۶۳۲۸۸۸	۰.۳۰۶۱۲۴	۱۰-۸-۱۰	Purelin	
۰.۸۱۰۳۹۸	۰.۶۱۹۲۴۳	۱۰-۱۰	Tansig	Trainlm
۰.۷۸۴۸۸	۰.۶۶۳۲۳۹	۱۰-۶-۱۰	Logsig	
۰.۶۳۱۶۹۴	۰.۳۰۴۹۷۶	۸-۱۰-۱۰	Purelin	
۰.۷۳۴۵۳۲	۰.۴۰۸۱۶۸	۱۰-۱۰	Tansig	Trainbfg
۰.۷۲۰۹۶	۰.۴۴۱۰۶۵	۸-۱۰	Logsig	
۰.۶۲۹۵۴۱	۰.۳۰۶۴۱۹	۱۰-۶	Purelin	
۰.۸۰۱۶۷۶	۰.۶۹۷۹۰۳	۶-۱۰-۸	Tansig	trainbr
۰.۷۹۹۳۳۹	۰.۷۰۷۰۲	۶-۱۰-۸	Logsig	

بر اساس مدل شبکه عصبی وزن و بایاس بر اساس جدول (۶) زیر تعیین شد. که بر اساس معادله زیر برای پیش‌بینی خواص
فیزیکی به کار می‌رود.

$$\sum_{k=1}^n Y_k = \sum_{i=1}^n f(W_{ij} X_i) + b_j \quad (1)$$



جدول ۶: ماتریس وزنهای (weight) مدل شبکه عصبی برای خواص کیفی در الگوریتم آموزش BR

Logsig 6-10-10										
B1			IW1							
۰٫۲۵۱	۰٫۰۲۵	۰٫۰۲۹	۱٫۲۵۴	۱٫۰۳۶	۲٫۲۷۸	-۱٫۳۹۱	-۰٫۱۶۲	-۰٫۲۸۱		
۱٫۰۳۲	-۰٫۷۹۶	۲٫۰۷۹	۰٫۹۶۱	۰٫۶۰۵	-۱٫۲۸۸	۰٫۵۱۸	۱٫۴۴۶	۰٫۲۸۷		
۰٫۷۴	۰٫۲۶۴	۰٫۰۴۷	-۰٫۲۰۳	۰٫۱۸۲	۳٫۸۰۱	-۰٫۴۴۹	۰٫۰۴۴	۰٫۰۴۲		
۰٫۹۴۸	۱٫۰۳۹	-۰٫۲۴۴	۲٫۸۶۲	-۰٫۴۴۶	۰٫۲۲۶	۰٫۴۷۵	-۰٫۲۹۶	-۰٫۲۰۷		
۰٫۶۳۲	-۰٫۵۱۶	-۱٫۱۱۰	۱٫۱۵۶	۰٫۴۲۶	۰٫۹۲۹	۱٫۶۹۴	۰٫۳۳۲	۰٫۰۱۱		
۰٫۱۸۷	-۰٫۰۷۳	۲٫۰۳۶	-۰٫۴۸۵	-۱٫۲۵۲	۰٫۰۸۰	۲٫۶۷۳	-۱٫۱۶۱	-۰٫۱۴۲		
b2			LW1							
	-۰٫۵۷۰	-۱٫۰۳۵	-۰٫۷۳۴	۱٫۷۳۲	۰٫۱۴۹	۰٫۷۷۶	-۰٫۳۴۷			
	-۰٫۹۸۵	۱٫۲۳۳	۲٫۶۴۳	۰٫۶۰۴	-۰٫۱۵۵	۰٫۵۴۲	-۱٫۶۱۹			
	۰٫۱۷۸	۰٫۱۹۷	-۲٫۰۷۵	-۲٫۴۳۵	-۱٫۳۳۴	-۱٫۲۱۱	-۱٫۰۴۲			
	-۰٫۳۹۳	-۰٫۱۷۸	-۰٫۰۰۷	۱٫۰۱۳	۰٫۶۴۶	۰٫۸۱۲	۰٫۹۵۳			
	۰٫۴۷۱	۰٫۲۱۱	-۲٫۲۲۴	-۰٫۹۲۲	۰٫۱۰۱	۱٫۵۳۲	-۱٫۳۴۶			
	-۰٫۴۹۸	۱٫۵۳۹	-۲٫۳۹۹	-۱٫۴۴۰	۰٫۲۲۹	-۲٫۰۲۴	-۰٫۵۶۰			
	-۰٫۱۳۴	-۰٫۸۲۷	-۱٫۳۳۷	۰٫۳۹۴	-۲٫۷۰۲	۱٫۱۰۹	۱٫۲۳۰			
	۰٫۷۰۷	-۰٫۷۸۲	۰٫۸۰۷	-۰٫۴۱۶	-۲٫۷۳۴	۰٫۸۵۱	-۰٫۹۶۷			
	۰٫۴۵۹	۰٫۱۳۳	-۰٫۴۹۷	۰٫۳۲۷	-۰٫۹۵۰	-۰٫۳۰۱	-۰٫۳۸۳			
	۰٫۰۶۹	۲٫۴۵۸	۰٫۳۶۹	-۲٫۱۲۷	۱٫۹۰۰	۰٫۱۱۹	۱٫۶۰۱			
b3			LW2							
۰٫۳۰۱	-۳٫۵۱۱	۰٫۸۶۴	۲٫۷۵۳	۲٫۴۲۴	۲٫۷۱۳	۱٫۶۰۲	۰٫۴۶۸	۰٫۸۰۰	۰٫۷۲۵	۱٫۲۲۴
۰٫۳۱۷	-۰٫۱۱۲	-۰٫۰۵۰	-۰٫۶۱۴	-۰٫۲۰۳	-۰٫۴۲۰	۱٫۲۷۷	۰٫۰۲۲	۰٫۳۰۸	-۰٫۰۷۹	۰٫۰۹۶
۰٫۱۹۸	۳٫۵۵۵	-۰٫۷۵۲	-۰٫۰۵۷	-۱٫۳۵۳	-۰٫۱۵۱	۰٫۱۵۸	-۱٫۰۶۵	-۱٫۱۴۵	۰٫۳۸۹	۰٫۰۳۹
-۰٫۶۲۴	-۰٫۱۸۹	-۰٫۱۲۱	۰٫۷۱۶	۰٫۴۳۹	-۰٫۶۱۴	۰٫۳۴۱	۰٫۳۴۱	-۰٫۰۶۶	۰٫۵۰۸	-۰٫۴۶۱
-۰٫۳۲	۰٫۳۰۷	-۱٫۰۵۵	-۲٫۶۹۳	-۰٫۰۶۴	-۱٫۰۱۶	-۱٫۰۳۴	-۰٫۰۸۱	۱٫۱۹۶	۲٫۷۰۵	-۰٫۹۳۴
-۰٫۰۰۹	۱٫۶۸۴	۰٫۱۷۷	-۱٫۳۸۳	-۱٫۹۸۲	-۰٫۸۱۹	-۰٫۰۴۱	-۰٫۰۷۹	-۱٫۱۹۷	-۱٫۰۰۷	-۰٫۶۰۳
-۰٫۱۰۵	-۰٫۵۹۳	-۰٫۰۱۰	-۰٫۰۰۴	۰٫۷۰۶	۰٫۳۰۶	-۰٫۳۴۵	۰٫۴۴۰	۰٫۱۸۶	۰٫۴۲۹	-۰٫۰۲۰
-۰٫۷۰۸	۱٫۵۲۵	-۰٫۸۳۶	۰٫۰۲۳	-۱٫۱۶۱	۱٫۳۴۶	-۲٫۰۱۴	۱٫۱۸۹	-۲٫۰۷۷	۰٫۷۳۹	۱٫۰۸۴
-۰٫۰۵۱	-۱٫۳۴۶	۰٫۴۷۷	۲٫۱۳۶	۱٫۸۲۵	۰٫۶۴۹	۰٫۴۰۷	-۰٫۵۱۶	۱٫۴۸۹	-۰٫۵۱۹	۰٫۸۰۲
-۰٫۴۳۴	۰٫۰۶۹	۰٫۲۹۹	۰٫۵۳۵	-۰٫۳۲۸	-۰٫۰۳۷	۰٫۳۸۶	-۰٫۰۳۸	۰٫۲۸۰	۰٫۲۲۳	-۰٫۶۳۰
b4			LW3							
۰٫۳۲۴	۰٫۲۶۳	۰٫۴۵۰	۱٫۳۶۱	-۰٫۷۷۶	۱٫۱۸۴	-۰٫۶۲۵	-۰٫۶۲۲	۰٫۱۹۴	۰٫۴۵۳	-۱٫۴۸۱
-۰٫۰۸۵	-۰٫۳۷۴	-۰٫۶۱۹	۰٫۸۴۷	-۰٫۵۵۰	۱٫۷۰۵	-۱٫۹۱۳	۰٫۰۱۸	۲٫۱۴۵	-۰٫۴۶۶	۰٫۴۳۸
-۰٫۱۰۲	-۰٫۹۰۷	۰٫۴۶۲	۲٫۲۷۰	۰٫۲۴۷	-۰٫۹۴۱	۰٫۰۴۶	-۱٫۲۱۳	-۰٫۳۳۰	-۱٫۳۹۸	۳٫۲۳۹
-۰٫۷۰۳	-۰٫۳۵۸	۱٫۴۴۳	۱٫۱۵۶	-۰٫۳۷۵	-۰٫۹۲۰	-۰٫۱۸۸	-۰٫۳۸۹	۰٫۳۷۸	-۱٫۳۴۰	۲٫۲۹۸
-۰٫۱۷	-۰٫۴۹۵	-۰٫۵۵۴	-۰٫۶۹۲	-۰٫۰۲۵	-۰٫۴۶۱	۳٫۱۱۷	۰٫۱۲۲	۲٫۶۲۱	۰٫۷۳۰	-۰٫۳۹۰

نتیجه‌گیری کلی

در خواص کیفی مدل رگرسیون برای میزان مواد جامد محلول جواب نداده و در pH نیز فقط در شرایط محیطی مناسب بود. بهترین مقدار R^2 در pH برای مدل ترکیبی ۸۴/۹٪ شد. الگوریتم trainbr بهترین عملکرد را داشت. با توجه به مقدار خطا بهترین توپولوژی در تابع tansig ۸-۱۰-۶ و در تابع logsig با همان توپولوژی انتخاب شد. مقادیر MSE و R برای این دو مدل به ترتیب ۰/۰۰۶۶ و ۹۲/۱ بدست آمد. با توجه به مقایسه دو روش، مدل شبکه عصبی برای پیش‌بینی بهتر عمل می‌کند.

منابع

- Anonymous. 2002. Oakdale engineering. Datafit programming.
- Anonymous. 2009. Agriculture Database of FOA-STAT. Available at <http://faostat.fao.org/faostat/form?collection=Production.Crops.Primary&Domain=Production&servlet=1&hasbulk=0&version=ext&language=EN>.
- Bhatt A. K., Pant D. and Singh R. 2014. An analysis of the performance of Artificial Neural Network technique for apple classification. AI & Soc (2014) 29:103–111.
- Bhatt A. K. and Pant D. 2015. Automatic apple grading model development based on backpropagation neural network and machine vision, and its performance evaluation. AI & Soc (2015) 30:45–56.
- Demuth H. and Beale M. 200). Neural Network Toolbox For Use with MATLAB. The MathWorks, Inc.
- Embuscado M. E. and Huber K. C. 2009. Edible Films and Coatings for Food Applications. Springer.
- Zarifneshat S., Rohani A., Ghassemzadeh H. R., Sadeghi M., Ahmadi E., Zarifneshat M. 2012. Predictions of apple bruise volume using artificial neural network. Computers and Electronics in Agriculture 82 :75–86.