

درجه‌بندی مغز گردو بر اساس رنگ با استفاده از ترکیب ماشین بینایی و شبکه

عصبی مصنوعی^۱

Color Grading of Walnut Kernel Using Combination of Machine Vision and Artificial Neural Networks

مهدی کسرائی، علیرضا خوشرو* و محمد حاجی زاده^۲

چکیده

در این پژوهش به منظور درجه‌بندی رنگی مغز گردو نژادگان بوانات طبق استاندارد بین‌المللی به چهار درجه خیلی روشن، روشن، روشن کهربایی و کهربایی، ۱۵۹ مغز گردو انتخاب و از هر یک جداگانه تصویربرداری شد. در مرحله پردازش تصویر، با استفاده از فیلتر لاپلاسیس گوسی زمینه جداسازی شد و ۱۲ ویژگی رنگی شامل میانگین و انحراف معیار رنگ‌های قرمز، سبز و آبی و هم‌چنین میانگین و انحراف معیار اصل رنگ، درجه اشباع و شدت رنگ استخراج شد. به منظور رتبه‌بندی ویژگی‌ها از شاخص میانگین مربعات همبستگی کانونی استفاده شد که بر این اساس میانگین شدت رنگ بیشترین تأثیر را در مدل رتبه‌بندی داشت و پس از آن میانگین اشباع و واریانس شدت رنگ مهم‌ترین ویژگی‌ها در مدل رتبه‌بندی بودند. با توجه به مدل رتبه‌بندی ویژگی‌ها، شبکه‌های عصبی با ورودی‌های متفاوت از یک تا ۱۲ ورودی طراحی شد. با استفاده از ۹ ویژگی مهم‌تر به‌عنوان ورودی شبکه عصبی، بالاترین دقت درجه‌بندی برابر با ۹۵/۸٪ در ساختار بهینه ۴-۲۰-۹ به‌دست آمد که دقت درجه‌بندی برای مغز گردو با درجه خیلی روشن ۱۰۰٪، درجه روشن ۹۲/۳۱٪، درجه روشن کهربایی ۹۰/۹۱٪ و درجه کهربایی ۱۰۰٪ بود. نتیجه این پژوهش نشان‌دهنده توانایی بالای ماشین بینایی در ترکیب با شبکه عصبی برای درجه‌بندی مغز گردو بر اساس رنگ می‌باشد.

واژه‌های کلیدی: پردازش تصویر، پرسپترون چند لایه، رتبه‌بندی ویژگی‌ها، فیلتر لاپلاسیس گوسی.

مقدمه

ایران جایگاه مهمی در تولید گردو در سطح بین‌المللی دارد و پس از چین و آمریکا سومین تولیدکننده جهانی گردو است. در دو دهه گذشته، تولید سالانه گردو در ایران افزایش چشمگیری داشته است و از ۱۱۰ هزار تن در سال ۱۳۷۲ به ۳۴۹ هزار تن در سال ۱۳۹۶ افزایش یافته است (۵). گردو با داشتن مقدار زیادی ویتامین B نقش مفیدی در سلامت انسان دارد (۸). مغز گردو بیشتر به‌صورت خشکبار استفاده می‌شود و به همین دلیل رنگ روشن آن نقش مهمی در جلب رضایت مشتری دارد. مغز گردو‌هایی که کیفیت مناسبی ندارند، به صورت پودر شده در صنایع غذایی و یا در صنایع داروسازی استفاده می‌شوند. در ایران، درجه‌بندی مغز گردو به‌طور معمول به روش دستی انجام می‌شود. با توجه به دشواری‌های ناشی از این روش، استفاده از سیستم‌های درجه‌بندی مبتنی بر ماشین بینایی می‌تواند جایگزین مناسبی باشد. در سال‌های اخیر پیشرفت‌های زیادی در زمینه کاربرد ماشین بینایی برای درجه‌بندی محصول‌های کشاورزی صورت گرفته است (۲۲، ۲۳). مثال‌هایی از این کاربردها، رسیدگی انار (۱۴) و درجه‌بندی پسته (۲۰) می‌باشند.

۱- تاریخ دریافت: ۹۷/۹/۲۵

تاریخ پذیرش: ۹۸/۷/۱

۲- به ترتیب استادیار بخش مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه شیراز، استادیار گروه زراعت و اصلاح نباتات، دانشکده کشاورزی، دانشگاه یاسوج و دانشجوی پیشین کارشناسی ارشد مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه شیراز، شیراز، ایران.

* نویسنده مسئول، پست الکترونیک: (khoshroo@yu.ac.ir).

یکی از مراحل مهم درجه‌بندی محصول‌های کشاورزی، انتخاب ویژگی‌های مناسب برای تعیین کیفیت و درجه مورد نظر می‌باشد. در بین ویژگی‌های مهم مورد مطالعه (رنگ، بافت و شکل محصول) ویژگی رنگ استفاده گسترده‌تری در پژوهش‌های کشاورزی داشته است (۲۴). درجه‌بندی مغز گردو مطابق استانداردهای بین‌المللی می‌تواند در افزایش مشتری پسندی و گسترش صادرات این محصول در بازارهای رقابتی خارجی مؤثر باشد. بر اساس استاندارد بین‌المللی درجه‌بندی مغز گردو که توسط وزارت کشاورزی آمریکا ارائه شده است، مغز گردو از نظر رنگ به چهار گروه خیلی روشن^۱، روشن^۲، روشن کهربایی^۳ و کهربایی^۴ تقسیم‌بندی می‌گردد (۳، ۴). برای تشخیص این چهار گروه از تصاویر استاندارد استفاده می‌شود که نمونه‌ای از آن در شکل ۱ ارائه شده است.

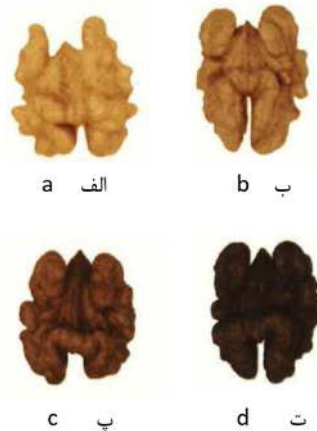


Fig. 1. USDA standard for walnut kernel grading, (a) Extra light, (b) Light, (c) Light amber, (d) Amber.

شکل ۱- استاندارد وزارت کشاورزی آمریکا برای درجه‌بندی مغز گردو: (الف) خیلی روشن، (ب) روشن، (پ) کهربایی روشن (ت) کهربایی.

دو فناوری اصلی مورد استفاده در شناسایی الگو، روش‌های یادگیری همراه با نظارت و یادگیری بدون نظارت می‌باشند. در یادگیری با نظارت داده‌های آموزشی شامل بردار ورودی همراه با مقادیر متناظر بردار هدف می‌باشد، در حالی که در یادگیری بدون نظارت، داده‌های آموزشی شامل بردار ورودی بدون مقادیر متناظر بردار هدف می‌باشد. در روش طبقه‌بندی که جزء یادگیری با نظارت می‌باشد، هر بردار ورودی به یک طبقه (کلاس) از پیش مشخص شده تخصیص می‌یابد (۶). در دو دهه گذشته تمایل زیادی به استفاده از شبکه‌های عصبی مصنوعی به عنوان الگوریتم طبقه‌بندی در بسیاری از زمینه‌های علمی وجود داشته است و با موفقیت در درجه‌بندی محصول‌های کشاورزی مورد استفاده قرار گرفته است (۹). یکی از مناسب‌ترین شبکه‌های عصبی مصنوعی در درجه‌بندی محصول‌های کشاورزی، شبکه عصبی پرسپترون چند لایه (MLP)^۵ می‌باشد (۱۵). در پژوهشی Nakano برای درجه‌بندی سیب بر اساس رنگ سطح میوه به ۵ گروه عالی، بسیار خوب، خوب، نامطلوب و آسیب دیده از شبکه عصبی مصنوعی استفاده کرد. هر چند دقت درجه‌بندی برای گروه‌های خوب و بسیار خوب، پائین و به ترتیب ۳۳/۳٪ و ۶۵/۱۸ بود، ولی دقت درجه بندی برای گروه‌های عالی، نامطلوب و آسیب دیده مقادیر بالایی داشت و به ترتیب ۹۲/۵٪، ۸۷/۲ و ۷۵٪ بود (۱۹). در پژوهشی به‌منظور شناسایی گردوهای سالم و پوک از روش‌های پردازش صوت و شبکه عصبی مصنوعی استفاده شد که شبکه MLP با ساختار بهینه ۱-۱۱-۱۲ با دقت بالایی جداسازی گردوها را انجام داد (۷). محمودی و همکاران (۱۶) محتوای کلروفیل برگ پنج رقم گردو را اندازه گیری کردند و آن را با خصوصیات رنگی برگ‌ها در دو فضای رنگی RGB و HSI مقایسه کردند. بر اساس نتیجه‌ها، مقدار اصل رنگ (H) بیشترین همبستگی را با محتوای کلروفیل داشت. میرزابه و همکاران (۱۸) ویژگی‌های فیزیکی چهار نژادگان گردو را با استفاده از پردازش تصویر بررسی کردند. آن‌ها اندازه‌های اصلی (طول، عرض و ضخامت) و سطح تصویر شده گردو را تعیین کردند. سپس بر اساس اندازه‌های اصلی گردو، میانگین هندسی قطر، کرویت، حجم و سطح مقطع گردو را محاسبه کردند (۱۸). در پژوهشی دیگر حاجی‌زاده و کسرایی

درجه‌بندی گردو را بر اساس جرم ویژه انجام دادند. در این پژوهش حجم گردو به سه روش شعاع مؤثر، مساحت سطح و مجموع المان‌ها از راه پردازش تصویر محاسبه شد و در نهایت جرم ویژه (نسبت جرم به حجم) در هر روش مشخص شد. بر اساس آستانه‌هایی که برای درجه‌بندی انتخاب شد، میوه گردو در ۳ گروه مختلف درجه‌بندی شد. مقادیر ضریب تبیین برای سه روش شعاع مؤثر، مساحت سطح و مجموع المان‌ها به ترتیب ۰/۸۲، ۰/۹۴ و ۰/۸۷ به دست آمد که روش مساحت سطح به دلیل داشتن ضریب تبیین بالاتر نسبت به دو روش دیگر مناسب‌تر بود. در نهایت مقادیر واقعی و محاسبه شده جرم ویژه بر اساس آستانه‌های انتخابی مورد مقایسه قرار گرفت که خطای درجه‌بندی در سه روش شعاع مؤثر، مساحت سطح و مجموع المان‌ها به ترتیب ۳، ۶/۶ و ۶/۶ درصد به دست آمد (۲).

هدف از انجام این پژوهش بررسی امکان استفاده از ویژگی‌های رنگی در دو فضای RGB و HSI و روش شبکه عصبی مصنوعی برای تشخیص درجه کیفیت مغز گردو بر اساس استاندارد بین‌المللی می‌باشد.

مواد و روش‌ها

آماده‌سازی نمونه‌ها

در این پژوهش به منظور درجه‌بندی مغز گردو (*Juglans regia L.*) نژادگان یونان به چهار گروه بر اساس استاندارد بین‌المللی، ابتدا تعداد ۱۵۹ مغز گردو که درجه‌بندی آن‌ها مورد توافق سه کارشناس خبره به‌طور چشمی قرار گرفته بود، جداسازی شدند. بر این اساس تعداد مغز گردوهای درجه‌بندی شده در کلاس‌های خیلی روشن، روشن، روشن کهربایی و کهربایی به ترتیب ۵۰، ۳۸، ۳۹ و ۳۲ عدد بود. روش درجه‌بندی رنگی ارائه شده در این پژوهش، مستقل از اندازه مغز گردو می‌باشد و امکان استفاده برای مغز گردوها با هر نوع اندازه را دارد.

پردازش تصاویر

مراحل مختلف پردازش تصویر مغز گردو و استخراج ویژگی‌های رنگی آن در فلوچارت زیر آورده شده است.



تهیه تصاویر

برای تهیه تصاویر مغز گردوهای مورد استفاده در این پژوهش و استخراج ویژگی‌های رنگی آن‌ها از یک محفظه تصویر برداری استفاده شد. این محفظه شامل جعبه مستطیلی به اندازه‌های $60 \times 60 \times 50$ سانتی‌متر بود. سیستم نورپردازی از دو لامپ هالوژن ۱۰۰ واتی جریان مستقیم تشکیل شده بود که در دو گوشه جعبه به طور متقارن قرار گرفته بودند. مغز گردو در وسط محفظه قرار داده شد و با یک دوربین دیجیتال Cannon مدل Powershot A700 که در سطح بالایی محفظه روبروی مغز گردو مستقر شده بود، تصویربرداری انجام شد. فاصله دوربین نسبت به مغز گردو ثابت در نظر گرفته شد و میدان دید دوربین تنها سطح پایین محفظه که شامل مغز گردو بود را شامل می‌شد. سطح افقی جعبه که مغز روی آن قرار می‌گرفت نیز به رنگ سفید در آمده بود تا جداسازی گردو از زمینه سبب پیچیدگی الگوریتم پردازش نشود. در شکل ۲ به طور شماتیک محفظه تصویربرداری نشان داده شده است (۱).

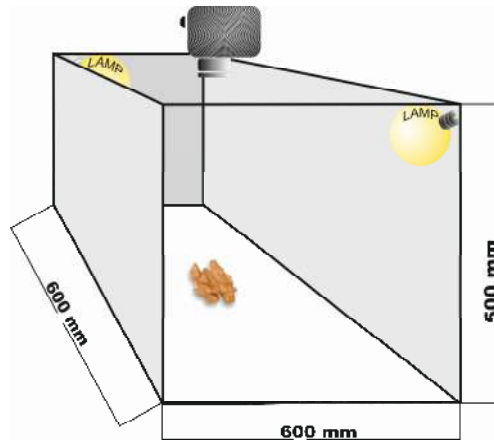


Fig. 2. Imaging chamber of walnut kernel.

شکل ۲- محفظه تصویربرداری مغز گردو.

پیش پردازش

در مرحله بعدی پردازش تصاویر انجام شد که شامل بخش‌بندی تصویر و جداسازی مغز گردو از زمینه بود. در این قسمت از روش‌های تشخیص لبه استفاده شد. فیلتر مورد استفاده لاپلاسیان گوسی بود. با در نظر گرفتن تابع $h(r) = -\exp(-\frac{r^2}{2\sigma^2})$ که در آن $r^2 = x^2 + y^2$ و σ انحراف معیار می‌باشد، لاپلاسیان h (مشتق دوم h نسبت به r) به صورت زیر محاسبه شد (۱۱).

$$\nabla^2 h(r) = -\left[\frac{r^2 - \sigma^2}{\sigma^4} \right] e^{-\frac{r^2}{2\sigma^2}} \quad (1)$$

این تابع لاپلاسیان گوسی نامیده می‌شود زیرا $h(r)$ به فرم تابع گوسی است. در مرحله پیش پردازش و بخش‌بندی ابتدا لایه قرمز تصویر از تصویر رنگی جدا شد و پردازش روی آن انجام گرفت، سپس با استفاده از تابع لاپلاسیان گوسی لبه‌های تصویر استخراج شد. با توجه به پیوستگی لبه در مرز با زمینه، قسمت داخلی آن با استفاده از روش پرکردن حفره‌ها در نرم‌افزار MATLAB، با رنگ سفید پر شد و زمینه به رنگ مشکی درآمد و حذف شد. در مرحله بعد با ضرب داخلی این تصویر در لایه‌های قرمز، سبز و آبی تصویر اصلی زمینه جدا شد و تصاویر لایه‌های قرمز، سبز و آبی که زمینه آن‌ها حذف شد، جهت پردازش رنگی مورد استفاده قرار گرفتند.

استخراج ویژگی‌های رنگی

پس از حذف زمینه از تصاویر گردو در دو فضای رنگی RGB و HSI آنالیز رنگ انجام شد. مقادیر HSI را می‌توان از مقادیر متناظر RGB با استفاده از معادله‌های ۲ تا ۴ محاسبه نمود (۲۱).

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} \begin{bmatrix} 0.3333 & 0.3333 & 0.3333 \\ 1 & -0.5 & -0.5 \\ 0 & 0.866 & 0.866 \end{bmatrix} = \begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix} \quad (2)$$

$$H = \arctan \left(\frac{V_2}{V_1} \right) \quad (3)$$

$$s = (V_1^2 + V_2^2)^{0.5} \quad (4)$$

که در این معادلات H اصل رنگ، S شدت اشباع و I شدت رنگ می‌باشد. بنابراین از هر تصویر دو ویژگی میانگین و انحراف معیار از کانال‌های اصلی رنگی تصویر (R, G, B, H, S) استخراج شد. برای تعیین پارامترهای رنگی هر یک از تصاویر حاصله، از جعبه ابزار پردازش تصویر نرم‌افزار MATLAB R2015b استفاده شد.

شبکه عصبی مصنوعی

در این پژوهش برای درجه بندی مغز گردو به چهار کلاس، از شبکه عصبی MLP با الگوریتم پس‌انتشار خطا شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی استفاده گردید (شکل ۳). مراحل طراحی شبکه عصبی مصنوعی با استفاده از نرم‌افزار MATLAB R2018 انجام گرفت. از ۱۵۹ تصویر رنگی، ۸۸ تصویر برای آموزش شبکه عصبی، ۲۳ تصویر برای اعتبارسنجی شبکه و ۴۸ تصویر برای آزمون شبکه عصبی استفاده شدند. ویژگی‌های رنگی به‌دست آمده از پردازش تصاویر گردو شامل شش ویژگی میانگین و انحراف معیار R, G و B در فضای RGB و شش ویژگی میانگین و انحراف معیار H, S و I در فضای HSI به عنوان ورودی شبکه عصبی MLP استفاده شد. برای این‌که شبکه بتواند روابط غیرخطی را تشخیص دهد، از تابع فعال‌سازی تانژانت هیپربولیک برای لایه پنهان استفاده گردید. تعداد نرون‌های لایه پنهان از عوامل مهم در طراحی شبکه عصبی MLP می‌باشند (۱۲). تعداد نرون‌ها در لایه پنهان بر اساس کمینه خطای اعتبارسنجی تعیین شد. لایه خروجی با توجه به چهار کلاس مغز گردو شامل چهار نرون بود که هر نرون بیانگر مقدار پیش‌بینی هر یک از کلاس‌ها بود. در نهایت اعداد خروجی از نرون‌ها با یکدیگر مقایسه شدند و نرون دارای بزرگ‌ترین مقدار خروجی به عنوان کلاس خروجی انتخاب شد. همچنین، معیار بررسی خطا در شبکه عصبی طراحی شده، میانگین مربع‌های خطا بود.

برای ارائه خلاصه عملکرد درجه‌بندی از ماتریس اغتشاش استفاده شد. هر ستون ماتریس اغتشاش نشان‌دهنده کلاس پیش‌بینی شده نمونه‌ها بر اساس روش درجه‌بندی استفاده شده می‌باشد، در حالی که هر ردیف ماتریس نشان‌دهنده نمونه‌ها در کلاس واقعی می‌باشد. نمونه‌هایی که روی قطر اصلی ماتریس قرار گرفته‌اند به صورت صحیح درجه‌بندی شده‌اند (۱۳). دقت درجه‌بندی بیانگر میزان درجه‌بندی صحیح سیستم است و برابر با تعداد پیش‌بینی صحیح تقسیم بر تعداد کل پیش‌بینی‌های انجام شده ضرب در ۱۰۰ می‌باشد، به عبارت دیگر، دقت مجموع اعداد روی قطر اصلی ماتریس اغتشاش تقسیم بر کل نمونه‌های مورد مطالعه ضرب در ۱۰۰ می‌باشد. دقت هر کلاس نشان‌دهنده میزان درجه‌بندی صحیح هر کلاس است و از تقسیم تعداد نمونه‌های کلاس که صحیح درجه‌بندی شده‌اند بر تعداد نمونه‌های بررسی شده آن کلاس به‌دست می‌آید (۱۳).

انتخاب ویژگی

به‌منظور رتبه‌بندی و مشخص کردن درجه اهمیت ویژگی‌ها از شاخص میانگین مربع‌های همبستگی کانونی (ASCC) استفاده گردید که مقدار این شاخص به صورت جمعی می‌باشد. همچنین به‌منظور بررسی تأثیر جداگانه هر ویژگی و درجه اهمیت آن در درجه‌بندی، هر ویژگی به صورت جداگانه مورد تحلیل قرار گرفت و شاخص ASCC برای آن محاسبه شد و بر این اساس رتبه‌بندی ویژگی‌ها انجام گرفت. در صورتی که چند ویژگی دارای همبستگی بالا باشند در مدل رتبه‌بندی این ویژگی‌ها می‌توانند تأثیر منفی داشته باشند و باعث کاهش اهمیت آن‌ها در مدل رتبه‌بندی گردند (۱۷).

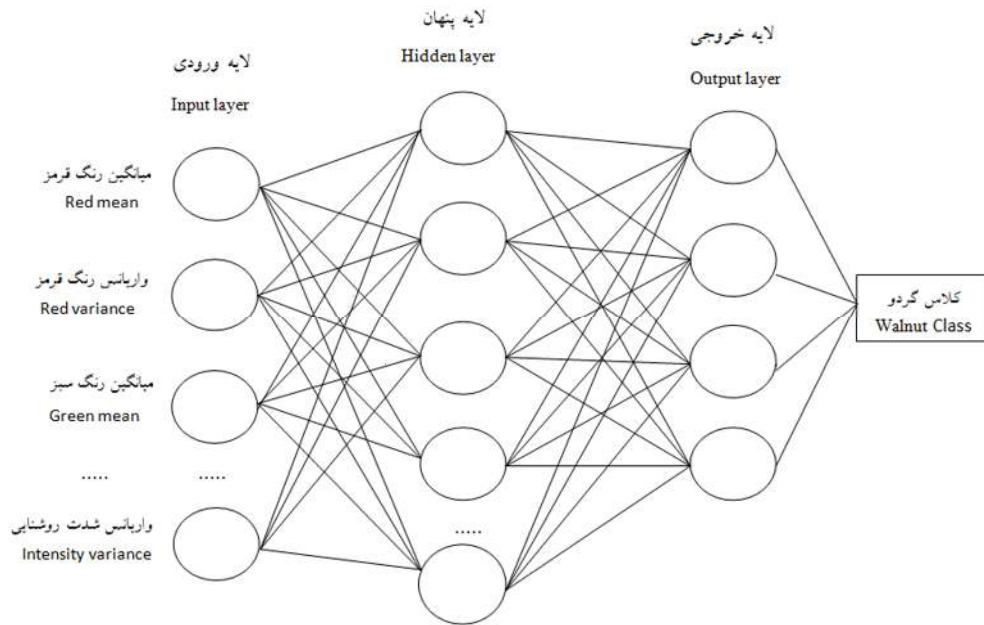


Fig. 3. Neural network structure.

شکل ۳- ساختار شبکه عصبی.

نتایج و بحث

در شکل ۴ نتیجه‌های لبه‌یابی به روش لاپلاسین گوسی و پیش‌پردازش‌های انجام شده روی تصاویر مغز گردو نشان داده شده است. کیفیت مناسب جداسازی زمینه با استفاده از روش لاپلاسین گوسی به صورت چشمی قابل مشاهده است. پس از جداسازی زمینه، مقادیر میانگین قرمز، سبز و آبی هر تصویر استخراج شد. سپس مقادیر میانگین اصل رنگ، شدت اشباع و شدت رنگ در هر تصویر با استفاده از معادله‌های ۲ تا ۴ محاسبه شد.




Fig. 4. Image pre-processing steps: (a) main color image, (b) Edge detection using LoG, (c) Filling the holes and background removing, (d) Red channel, (e) Green channel, (f) Blue channel.

شکل ۴- مراحل پیش‌پردازش تصویر: (الف) تصویر رنگی اصلی، (ب) لبه‌یابی با لاپلاسین گوسی، (پ) پرکردن حفره‌ها و حذف پس‌زمینه، (ت) لایه قرمز تصویر، (ث) لایه سبز تصویر، (ج) لایه آبی تصویر.

نتیجه‌های رتبه‌بندی ویژگی‌ها با استفاده از شاخص ASCC در جدول ۱ ارائه شده است. بر اساس نتیجه‌های این جدول، میانگین شدت رنگ بیشترین تأثیر را در مدل رتبه‌بندی داشت (ASCC=۰/۲۵۵) و پس از آن میانگین اشباع (ASCC=۰/۳۰۱) و واریانس شدت رنگ (ASCC=۰/۳۳۹) مهم‌ترین ویژگی‌ها در مدل رتبه‌بندی بودند، در حالی که میانگین رنگ قرمز دارای کمترین اهمیت در مدل رتبه‌بندی بود (ASCC=۰/۴۳۱) که دلیل آن همبستگی بالای رنگ قرمز با دیگر ویژگی‌های مورد مطالعه در مدل درجه‌بندی می‌باشد. بر اساس نتیجه‌های جدول ۱، در بین شش ویژگی مهم‌تر در مدل، پنج میانگین شامل میانگین شدت رنگ، میانگین اشباع، میانگین آبی، میانگین سبز و میانگین اصل رنگ قرار داشتند، بنابراین اهمیت ویژگی‌های میانگین مورد مطالعه بسیار بیشتر از واریانس بود.

جدول ۱- مدل رتبه‌بندی ویژگی‌های رنگی در درجه‌بندی مغز گردو.

Table 1. Ranking model of color features in walnut kernel grading.

ویژگی Feature	ASCC	r ²
میانگین شدت رنگ Intensity mean	۰/۲۵۳	۰/۷۶
میانگین اشباع Saturation mean	۰/۳۰۱	۰/۳۴
واریانس شدت رنگ Intensity variance	۰/۳۳۹	۰/۱۶
میانگین آبی Blue mean	۰/۳۵۲	۰/۱۱
میانگین سبز Green mean	۰/۳۸۸	۰/۱۵
میانگین اصل رنگ Hue mean	۰/۴۰۲	۰/۰۵
واریانس آبی Blue variance	۰/۴۱۲	۰/۰۴
واریانس اصل رنگ Hue variance	۰/۴۱۴	۰/۰۴
واریانس سبز Green variance	۰/۴۱۹	۰/۰۴
واریانس اشباع Saturation variance	۰/۴۲۱	۰/۰۴
واریانس قرمز Red variance	۰/۴۳۰	۰/۰۵
میانگین قرمز Red mean	۰/۴۳۲	۰/۰۱

با توجه به مدل رتبه‌بندی ویژگی‌ها، شبکه‌های عصبی با ورودی‌های متفاوت از یک تا ۱۲ ورودی طراحی شد. به طوری که در شبکه عصبی با یک ورودی میانگین شدت رنگ به عنوان ورودی به مدل داده شد و در شبکه عصبی با پنج ورودی، پنج ویژگی مهم‌تر بر اساس مدل رتبه‌بندی به شبکه داده شد. برای هر تعداد ویژگی ورودی، شبکه‌های عصبی با توپولوژی متفاوت بررسی شد و ساختار بهینه آن‌ها انتخاب شد. برای مثال روش انتخاب شبکه عصبی بهینه با ۹ ورودی توضیح داده می‌شود. این شبکه دارای ۹ نرون در لایه ورودی و ۴ نرون در لایه خروجی می‌باشد. به منظور جلوگیری از ورآموزی شبکه، کمینه خطای داده‌های آموزش و اعتبارسنجی معیار ارزیابی تعداد بهینه نرون در لایه پنهان قرار گرفت. بررسی روند خطا با تعداد نرون در لایه پنهان نشان داد که کم‌ترین خطای درجه‌بندی به صورت همزمان برای داده‌های آموزش و اعتبارسنجی، با ۲۰ نرون در

لایه پنهان به دست آمد (شکل ۵). بنابراین، تعداد بهینه نرون در لایه پنهان، ۲۰ نرون انتخاب شد که بر این اساس بهترین توپولوژی شبکه ۴-۲۷-۹ انتخاب شد. این نتیجه تحقیق که شبکه عصبی با یک لایه پنهان می‌تواند با دقت بالایی درجه‌بندی را انجام دهد با نتیجه‌های تحقیق امید و همکاران همخوانی داشت (۲۰).

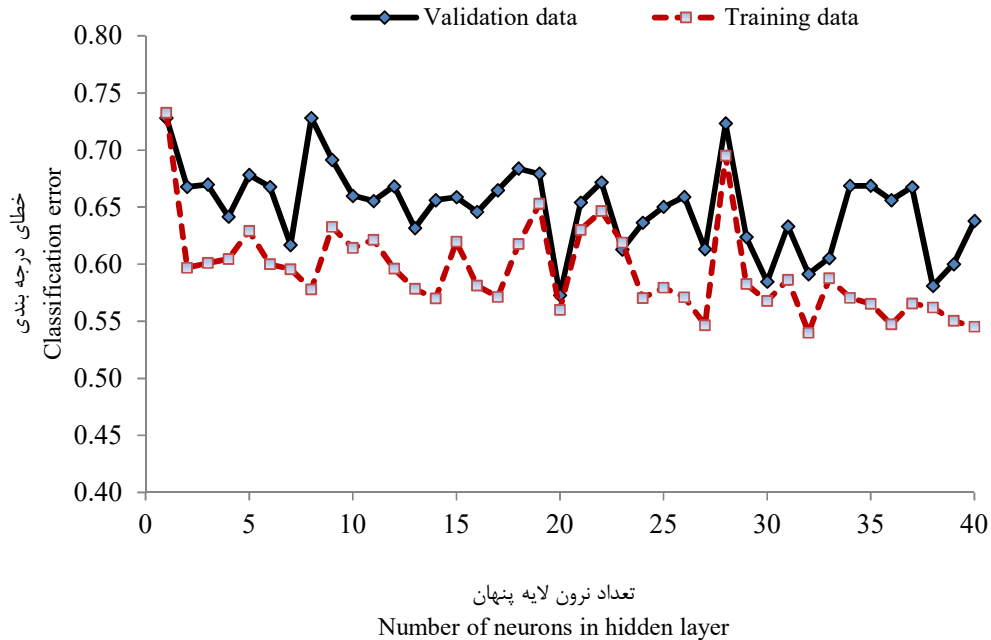


Fig. 5. Performance of artificial neural networks for different number of neurons in hidden layer.

شکل ۵- عملکرد شبکه‌های عصبی مصنوعی برای شمار متفاوت نرون در لایه پنهان.

شکل ۶ تأثیر تعداد ویژگی‌های ورودی بر دقت درجه‌بندی را نشان می‌دهد. مطابق شکل با افزایش تعداد ورودی شبکه عصبی مصنوعی به ۲ ویژگی، دقت درجه‌بندی به ۹۱/۷٪ رسید. پس از آن با افزایش ورودی تا ۵ ویژگی‌ها در دقت درجه‌بندی تغییری حاصل نشد که دلیل آن همبستگی معنی‌دار بین دو ویژگی مهم میانگین شدت رنگ و میانگین اشباع با هر سه ویژگی واریانس شدت رنگ، میانگین آبی و میانگین سبز بود. با افزودن میانگین اصل رنگ (ششمین ویژگی مهم) به ورودی شبکه عصبی دقت درجه‌بندی به ۹۳/۷٪ رسید و پس از آن با افزایش تعداد ویژگی‌های ورودی تا ۸ ویژگی، دقت درجه‌بندی ثابت ماند. با استفاده از ۹ ویژگی مهم‌تر در مدل بالاترین دقت درجه‌بندی برابر با ۹۵/۸٪ به دست آمد و پس از آن با افزایش ویژگی‌ها در ورودی شبکه عصبی، دقت درجه‌بندی ثابت ماند. دلیل ثابت ماندن دقت درجه‌بندی، وجود همبستگی بالا بین سه ویژگی کم اهمیت‌تر در مدل رتبه‌بندی شامل واریانس اشباع، واریانس قرمز و میانگین قرمز و بعضی از ویژگی‌های مهم‌تر بود. در نتیجه‌های مشابهی در درجه‌بندی بذر غلات بر اساس ویژگی‌های ریخت شناسی، با استفاده از ۱۰ ویژگی مهم‌تر بالاترین دقت درجه‌بندی به دست آمد و پس از آن با افزایش ویژگی‌ها دقت افزایش پیدا نکرد که دلیل آن وجود همبستگی بالا بین این ویژگی‌ها و ۱۰ ویژگی مهم‌تر بود (۱۷).

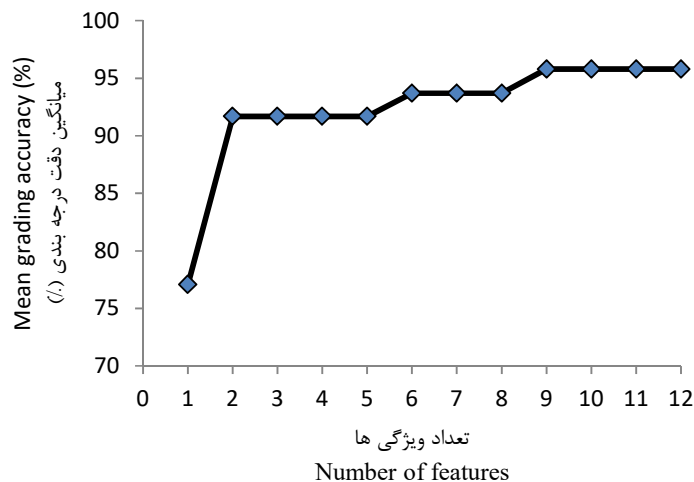


Fig. 6. Effect of number of features on accuracy of walnut kernel grading.

شکل ۶. تأثیر شمار ویژگی‌ها بر دقت درجه‌بندی مغز گردو.

در جدول ۲، نتیجه‌های دقت پیش‌بینی شبکه عصبی مصنوعی بهینه با ساختار ۴-۲۰-۹ برای چهار کلاس مغز گردو در قالب ماتریس اغتشاش ارائه شده است. دقت درجه‌بندی شبکه عصبی برای چهار کلاس مغز گردو با استفاده از داده‌های آزمون، ۹۵/۸٪ بود. این نتیجه با یافته‌های پژوهش غضنفری و همکاران همسو بود که در درجه‌بندی پسته با استفاده از شبکه عصبی مصنوعی نیز دقت درجه‌بندی ۹۵/۹٪ را گزارش نمودند (۱۰). همچنین در جدول ۳، دقت درجه‌بندی برای هر کلاس مغز گردو جداگانه ارائه شده است. بر این اساس دقت درجه‌بندی برای درجه خیلی روشن ۱۰۰٪، درجه روشن ۹۲/۳۱٪، درجه روشن کهربایی ۹۰/۹۱٪ و درجه کهربایی ۱۰۰٪ بود.

جدول ۲. ماتریس اغتشاش درجه‌بندی مغز گردو با استفاده از شبکه عصبی مصنوعی (داده‌های آزمون).

Table 2. Confusion matrix of ANN classifier for walnut kernel grading (test data).

مشاهده شده Observed	پیش‌بینی شده Predicted			
	درجه خیلی روشن Extra light grade	درجه روشن Light grade	درجه روشن کهربایی Light amber grade	درجه کهربایی Amber grade
درجه خیلی روشن (۱۵ نمونه) Extra light grade (15 samples)	15 (100%)	0	0	0
درجه روشن (۱۴ نمونه) Light grade (14 samples)	1	12 (92.31%)	1	0
درجه روشن کهربایی (۱۲ نمونه) Light amber grade (12 samples)	0	1	10 (90.91%)	1
درجه کهربایی (۹ نمونه) Amber grade (9 samples)	0	0	0	9 (100%)

Grading accuracy = 95.8%

دقت درجه بندی = ۹۵/۸٪

با توجه به دقت مطلوب درجه‌بندی، نتیجه‌های به‌دست آمده نشان‌دهنده توانایی بالای ماشین بینایی در ترکیب با شبکه عصبی مصنوعی برای درجه‌بندی مغز گردو می‌باشد و می‌توان این سامانه را به عنوان یک ابزار مناسب برای کنترل کیفیت این محصول به کار برد.

نتیجه‌گیری

در این پژوهش یک روش با استفاده از ماشین بینایی برای درجه‌بندی مغز گردو به چهار کلاس رنگی بر اساس استاندارد USDA ارائه شد. نتیجه‌های رتبه‌بندی ویژگی‌ها نشان داد که میانگین شدت رنگ، مهم‌ترین ویژگی در مدل

رتبه‌بندی بود (ASCC=۰/۲۵۵) و پس از آن میانگین اشباع و واریانس شدت رنگ بیشترین اهمیت را در مدل رتبه‌بندی داشتند، در حالی که میانگین رنگ قرمز دارای کمترین اهمیت در مدل رتبه‌بندی بود (ASCC=۰/۴۳۱). در شبکه عصبی با دو ورودی، دقت درجه‌بندی به ۹۱/۷٪ رسید و با افزایش نرون‌های ورودی به شش نرون، دقت درجه‌بندی ۹۳/۷٪ به‌دست آمد. بالاترین دقت درجه‌بندی شبکه عصبی هنگامی به‌دست آمد که از ۹ ویژگی مهم‌تر به عنوان ورودی شبکه عصبی استفاده شد. پس از آن با افزایش ویژگی‌ها در ورودی شبکه عصبی، دقت درجه‌بندی ثابت ماند. شبکه عصبی با توپولوژی ۴-۲۰-۹ بهترین عملکرد را در درجه‌بندی نشان داد که در این حالت دقت درجه‌بندی ۹۵/۸٪ به‌دست آمد که دقت درجه‌بندی برای مغز گردو با درجه خیلی روشن ۱۰۰٪، درجه روشن ۹۲/۳۱٪، درجه روشن کهربایی ۹۰/۹۱٪ و درجه کهربایی ۱۰۰٪ بود. بر اساس نتیجه‌ها، ماشین بینایی در ترکیب با شبکه عصبی مصنوعی توانایی شناسایی تغییرها در کیفیت مغز گردو را بر اساس رنگ طبق استاندارد USDA دارد.

References

منابع

۱. حاجی زاده، م. ۱۳۸۷. درجه‌بندی میوه گردو با استفاده از ماشین بینایی. پایان‌نامه‌ی کارشناسی ارشد رشته مهندسی مکانیک ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه شیراز. ۹۸ ص.
۲. حاجی زاده، م. و م. کسرایی. ۱۳۸۷. درجه‌بندی گردو با استفاده از ماشین بینایی بر اساس جرم ویژه. پنجمین کنگره ملی مهندسی ماشین‌های کشاورزی و مکانیزاسیون. انجمن مهندسی ماشین‌های کشاورزی و مکانیزاسیون ایران. مشهد. ۱۲ ص.
3. Anonymous. 1997. United States standards for Grades of Shelled Walnuts (*Juglans regia*). Provided by: United States Department of Agriculture, Agricultural Marketing Service, Fruit and Vegetable Division, Fresh Products Branch. 6 p.
4. Anonymous. 1994. Descriptors for Walnut. International Plant Genetic Resources Institute, Rome, Italy. 54 p.
5. Anonymous. 2013. FAO production yearbook. Food and Agriculture Organization, Rome.
6. Bishop, C. M. 2006. Pattern recognition and machine learning. Springer-Verlag, New York. 738 p.
7. Dousti, A., M. A. Ghazavi and A. Maleki. 2013. Grading of empty walnut using signal processing and artificial neural network techniques. Int. J. Agr. Crop Sci. 6:1072-1078.
8. Ebrahimi, A., A. Zarei, R. Fatahi and M. G. Varnamkhasti. 2009. Study on some morphological and physical attributes of walnut used in mass models. Sci. Hort. 121: 490-494.
9. Funes, E., Y. Allouche, G. Beltrán and A. Jiménez. 2015. A Review: Artificial Neural Networks as Tool for Control Food Industry Process. J. Sens. Technol. 5:28-43.
10. Ghazanfari, A., J. Irudayaraj and A. Kusalik. 1996. Grading pistachio nuts using a neural network approach. Trans. Amer. Soc. Agr. Engin. 39: 2319-2324.
11. Gonzalez, R. C. and R. Woods. 2002. Digital image processing. Prentice Hall Press. 793 p.
12. Haykin, S. 1999. Neural Networks A Comprehensive Introduction: Prentice Hall, New Jersey. 842 p.
13. Hagan, M. T., H. B. Demuth and M. H. Beale. 1996. Neural network design. Pws Publishing. Boston. 736 p.
14. Khoshroo, A., A. Keyhani, S. Rafiee, R. A. Zoroofi and Z. Zamani. 2009. Pomegranate quality evaluation using machine vision. Acta Hort. 818:347-352.
15. Khoshroo, A., A. Emrouznejad, A. Ghaffarizadeh, M. Kasraei, M. Omid. 2018. Sensitivity analysis of energy inputs in crop production using artificial neural networks. J. Cleaner Prod. 197:992-998.
16. Mahmoodi, M., J. Khazaei, K. Vahdati, N. Mohamadi and Z. Javanmardi. 2013. Chlorophyll Content Estimation Using Image Processing Technique. World Appl. Sci. J. 13:1-8.
17. Majumdar, S. and D. Jayas. 2000. Classification of cereal grains using machine vision: I. Morphology models. Trans. Amer. Soc. Agr. Engin. 43:1669-1675.
18. Mirzabe, A. H., A. Ráufi, A. Mansouri and K. Vahdati. 2014. Physical properties of walnut (*Juglans regia* L.) nuts and kernels. Adv. Crop Sci. 4(1):24-40.
19. Nakano, K. 1997. Application of neural networks to the color grading of apples. Comput. Electron. Agric. 18:105-116.
20. Omid, M., A. Mahmoudi, and M. H. Omid. 2009. An intelligent system for sorting pistachio nut varieties. Exp. Syst. Appl. 36:11528-11535.
21. Russ, J. C. 2016. The Image Processing Handbook. CRC Press. 885 p.
22. Sun, D.-W. 2012. Computer vision technology in the food and beverage industries. Woodhead Publishing, Cambridge, UK. 498 p.
23. Vithu, P. and J. Moses. 2016. Machine vision system for food grain quality evaluation: A review. Trends Food Sci. Technol. 56:13-20.
24. Zhang, B., W. Huang, J. Li, C. Zhao, C. Fan, J. Wu and C. Liu. 2014. Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. Food Res. Int. 62:326-343.

Color Grading of Walnut Kernel Using Combination of Machine Vision and Artificial Neural Networks

M. Kasraei, A. Khoshroo* and M. Hajizadeh¹

This paper aims at color grading of walnut kernels using a machine vision system. In this study, 159 kernels were divided into four color class of 'Extra Light', 'Light', 'Light Amber' and 'Amber' based on international standard. In image processing step, the Laplacian of Gaussian filter was used to remove the background of the image. Twelve color features were extracted from images including mean and standard deviation of red, green and blue as well as hue, saturation and intensity. The level of contribution of color features were determined using Average Squared Canonical Correlation values. The intensity mean had the highest contribution followed by saturation mean and intensity variance. Various neural networks architectures were developed with different number of inputs from one to 12 features based on the ranking model. Using the nine most important features as input for ANN, the highest grading accuracy of 95.8% obtained in the optimum structure of 9-20-4. The grading accuracy for walnut kernels in the classes of 'Extra Light', 'Light', 'Light Amber' and 'Amber' were 100%, 92.31%, 90.91% and 100%, respectively. The results show high potential of the machine vision combined with artificial neural network for color grading of walnut kernel.

Keywords: Image Processing; Features ranking; Laplacian of Gaussian filter; Multi-layer perceptron.

1. Assistant Professor, Department of Biosystem Engineering, Faculty of Agriculture, Shiraz University, Assistant Professor, Department of Agronomy and Plant Breeding, Faculty of Agriculture, Yasouj University and Former Student of Biosystem Engineering, Faculty of Agriculture, Shiraz University, Shiraz, Iran, respectively.

* Corresponding author, Email: (khoshroo@yu.ac.ir).