

شناسایی و تفکیک سه رقم برنج ایرانی در توده‌های مخلوط شده با استفاده از ویژگی‌های بافتی و شبکه عصبی LVQ

سعیده فیاضی^{1*}، محمدحسین عباسپور فرد²، سید امیرحسین منجمی³، حسن صدرنیا⁴ و عباس روحانی⁵

تاریخ دریافت: 91/11/30 تاریخ پذیرش: 92/6/18

- 1- گروه مهندسی ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد
 - 2- گروه مهندسی ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد
 - 3- گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه اصفهان
 - 4- گروه مهندسی ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد
 - 5- گروه مهندسی ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد
- *مسئول مکاتبه: E-mail:Fayyazi_s@yahoo.com

چکیده

با توجه به ارزش اقتصادی متفاوت ارقام برنج، گزارشات نشان دهنده این هستند که احتمال اختلاط ارقام مختلف در بازار وجود دارد. استفاده از تکنیک‌های پردازش تصویر و ابزارهای هوش مصنوعی برای طبقه‌بندی ارقام برنج، روشی است که می‌تواند دقت فرآیند طبقه‌بندی را در کاربردهای واقعی افزایش دهد. در این مطالعه چند گروه ویژگی بافتی از تصاویر دانه‌ها بررسی شدند تا کارایی آنها در شناسایی سه رقم برنج ایرانی (طارم، فجر، شیرودی) در نمونه‌های مخلوط این سه رقم ارزیابی شود. در مجموع 666 تصویر از دانه‌های برنج (222 تصویر از هر واریته) در شرایط نورپردازی ثابت گرفته شد و 41 ویژگی بافتی از ماتریس‌های سطوح خاکستری، هم‌وقوعی و الگوی دودویی محلی مربوط به تصاویر مقیاس خاکستری دانه‌ها استخراج شد. روش‌های ضریب فیشر، تحلیل اجزای اصلی و ترکیبی از این دو روش برای انتخاب ویژگی‌های با تأثیر دسته‌بندی بالا به کار برده شدند. برای دسته‌بندی نمونه‌های برنج در سه دسته مختلف از شبکه‌ی عصبی LVQ4 استفاده شد. دقت دسته‌بندی LVQ4، به ترتیب برای سه رقم فجر، شیرودی و طارم با استفاده از ویژگی‌های ماتریس سطوح خاکستری 97/96، 100 و 97/83 درصد، ماتریس هم‌وقوعی 96/23، 100 و 100 درصد، ماتریس الگوی دودویی محلی 97/50، 100 و 97/67 درصد، و با استفاده از کلیه‌ی ویژگی‌های ماتریس‌ها 100، 97/67 و 100 درصد بود. این نتایج نشان می‌دهند که پردازش تصویر ابزار مناسبی برای شناسایی ارقام مختلف برنج است. اگر چه استفاده از کلیه‌ی ویژگی‌ها منجر به خطای دسته‌بندی کمتری شده است، ولی ویژگی‌های بافتی هر یک از ماتریس‌های تصویر نیز به تنهایی دقت مطلوبی در تفکیک ارقام مورد مطالعه داشتند.

واژه‌های کلیدی: برنج، پردازش تصویر، شبکه عصبی، ویژگی‌های بافتی

1- مقدمه

همچنین به دلیل وجود گزارشاتی مبنی بر مخلوط کردن ارقام پر محصول (با ارزش اقتصادی کمتر) با ارقام گران قیمت و با کیفیت و فروش آنها در بازار به قیمت گران، استفاده از روشی که بتواند در مخلوط‌هایی که از دو یا چند نوع برنج هستند، نوع و درصد ارقام را مشخص کند، حائز اهمیت می‌باشد. علاوه بر آن ارائه توده‌های مخلوط بجای توده‌های با کیفیت خالص بتدریج این ذهنیت را در مشتریان ایجاد می‌کند که ارقام کم محصول با کیفیت، در حقیقت کیفیتی که اعلان می‌شود را ندارند؛ موضوعی که می‌تواند بتدریج باعث حذف ارقام با کیفیت از بازار گردد. بنابراین نیاز

برنج بعنوان یکی از مهم‌ترین غلات، منبع اصلی غذایی در جهان بشمار می‌رود و قوت غالب مردم ایران پس از گندم می‌باشد (بی‌نام، 1390). به همین دلیل مطالعه در مورد جنبه‌های مختلف آن از اهمیت زیادی برخوردار می‌باشد تا اطمینان حاصل شود که محصول تولید شده کیفیت لازم را دارا می‌باشد و می‌تواند رضایت مشتری را جلب کند.

عصبی پس انتشار برای دسته بندی وارپته‌ها استفاده شد. آنان درستی بالای 96/67 درصد را برای دسته بندی بدست آوردند.

ماجومدار و جایاس (2000) از ماشین بینایی برای دسته‌بندی دانه‌های غلات بر مبنای ویژگی‌های بافتی استفاده کردند و درستی دسته بندی بالای 76/3 درصد را بدست آوردند. زاپوتوکزی (2011) از تحلیل تصویر بر مبنای ویژگی‌های بافتی برای تفکیک ارقام گندم از شبکه‌های عصبی استفاده کرد. درستی دسته بندی 100 درصد برای 11 رقم گندم بدست آمد. پوررضا و همکاران (2012) از گروه‌های مختلف ویژگی بافتی برای شناسایی 9 رقم گندم ایرانی استفاده کردند و بالاترین دقت شناسایی را با استفاده از کلیه ویژگی‌های بافتی بدست آوردند. این مطالعات مبین آن است که استفاده از پردازش تصویر بر اساس ویژگی‌های بافتی، توانایی مطلوبی در شناسایی و تفکیک ارقام مختلف غلات از هم دارد.

هدف این تحقیق توسعه روشی برای شناسایی ارقام برنج در تصاویر گرفته شده از نمونه‌های ارقام مخلوط است تا بتوان به عنوان ابزاری برای شناسایی توده‌هایی که بصورت سهوی و یا عمدی به منظور سوء استفاده اقتصادی در بازار موجود است، استفاده نمود. به سه روش مختلف، بهترین ویژگی‌های بافتی تصاویر انتخاب شدند و نتایج حاصل از این سه روش از نقطه نظر دقت تفکیک، شناسایی و جداسازی در مرحله‌ی آزمایش شبکه عصبی با هم مقایسه گردیدند. پس از اتمام مرحله آزمایش و تعیین دقت تفکیک ارقام، می‌توان به اهدافی مانند درصد ارقام در هر نمونهی مخلوط نیز با دقتی مشابه دقت بدست آمده در مرحله‌ی آزمایش دست یافت.

2- مواد و روش‌ها

2-1- نمونه‌ها و سامانه تصویربرداری

در این مطالعه سه رقم رایج برنج ایرانی (طارم، فجر، شیرودی) از شهر ساری در شمال ایران تهیه و مورد بررسی قرار گرفتند. تصاویر همه‌ی وارپته‌ها از فاصله‌ی ثابت و تحت شرایط نورپردازی یکسان، در حالی که همه نمونه‌ها رطوبت یکسانی داشتند تهیه شد. از هر یک از ارقام سه گانه 222 تصویر گرفته شد. دوربین مورد استفاده مدل SONY DSC-HI بود و در هنگام تصویربرداری از بزرگنمایی 4X استفاده شد تا میدان دید دوربین، نمونه‌ها را تحت پوشش قرار دهد. تصاویر نمونه‌ها از میان توده‌های مخلوط (اما با دانه‌های جداگانه) تهیه شدند. نمونه‌ای از تصاویر ارقام مورد مطالعه در شکل 1 نشان داده شده است.

است که ارقام مختلف برنج قبل از عرضه به بازار بازبینی شوند تا در مورد خلوص آن‌ها اطمینان حاصل شود. به این منظور نیاز به تکنیک‌ها و روش‌هایی است که بتواند به شناسایی ارقام مختلف در توده‌های مخلوط بپردازد.

اگر چه در حال حاضر نیز امکان شناسایی توده‌های خالص و مخلوط از هم وجود دارد ولی با توجه به اینکه این روش‌ها عموماً دستی و با استفاده از نیروی انسانی صورت می‌گیرد، زمان بر هستند. بعلاوه چون این امور توسط افراد متخصص و با تجربه انجام می‌شود، بجز در موارد خاص، از نقطه نظر اقتصادی مقرون به صرفه نبوده و عمومیت دادن این روش‌های دستی توجیه اقتصادی ندارد. بنابراین ارائه روش‌های غیر دستی و نیمه خودکار که وابستگی آنها به نیروی انسانی کم باشد، می‌تواند در عمومیت دادن کنترل مخلوط‌های بازار نقش بسزایی ایفا نماید.

بررسی اجمالی مطالعات صورت گرفته بر روی تکنیک‌های پردازش تصویر نشان می‌دهند که این روش‌ها در ترکیب با تکنیک‌های طبقه بندی مانند شبکه‌های عصبی مصنوعی می‌توانند توانایی بالقوه‌ای را در اینگونه کاربردها داشته باشند.

تحلیل بافت تصویر، نسبت به اندازه‌گیری مستقیم شدت سطوح خاکستری، ابزار قدرتمندتری می‌باشد، زیرا که بافت تصویر، شامل اطلاعات آماری در حوزه‌ی فضایی می‌باشد (پارک و چن، 2001). همچنین بعضی توصیف گرهای بافتی مستقل از دوران، انتقال و تجانس هستند (هارلیک و همکاران، 1973) که این امر باعث آسان‌تر شدن استخراج ویژگی‌ها از تصاویر می‌شود و استفاده از الگوریتم‌های پیچیده را غیر ضروری می‌کند. از طرف دیگر، تحلیل بافت بر مبنای ویژگی‌های ماتریس هم وقوعی¹، یک ابزار قدرتمند برای تحلیل تصویر می‌باشد (پارک و چن، 2001). تاکنون تحقیقات زیادی برای شناسایی محصولات کشاورزی بر مبنای ویژگی‌های بافتی انجام گرفته است (پوررضا و همکاران، 2012)؛ از جمله آنها تحقیقات انجام گرفته برای شناسایی غلات می‌باشد که نمونه‌هایی از آنها در ادامه آمده است.

چن و همکاران (2009) از ویژگی‌های بافتی تصاویر چند طیفی برای تفکیک ارقام برنج بر مبنای گروه موجک و ماشین بردار پشتیبان² (SVM) استفاده کردند. نتایج بدست آمده توسط آنها مفید بودن این تکنیک را نشان داد. همچنین دسته بندی وارپته‌های برنج با استفاده از ویژگی‌های بافتی و رنگی و شبکه‌های عصبی پس انتشار (BP)³ انجام شد (موسوی راد و همکاران، 1390). پس از استخراج ویژگی‌های دانه‌ها، 22 ویژگی که بیشترین تأثیر را در دسته بندی داشتند توسط روش‌های آماری انتخاب شدند و از یک دسته بندی کننده‌ی شبکه

¹-Co-occurrence Matrix

²-Support Vector Machine

³- Back Propagation Neural Networks

جایاس، 1999)، هفت ثابت گشتاوری که غیر حساس به انتقال، دوران، تجانس و انعکاس می‌باشند (گنزلس و همکاران، به نقل از کیا، 1386) و 12 گروه فراوانی سطوح خاکستری (HG))⁴، 10 ویژگی از ماتریس هم وقوعی⁵ (میانگین، واریانس، آنتروپی، یکنواختی، همگنی⁶، اینرسی⁷، سایه خوشه⁸، برتری خوشه⁹، حداکثر احتمال¹⁰ و همبستگی (ماجومدار و جایاس، 1999) و 6 ویژگی از ماتریس الگوی دودویی محلی¹¹ (میانگین، انحراف معیار، همواری، ممان سوم، یکنواختی و آنتروپی) (پوررضا و همکاران، 2012) استخراج گردید. به منظور استخراج ویژگی های گروه فراوانی سطوح خاکستری، 256 مقدار ممکن سطوح خاکستری در بازه بین صفر تا 255 به 25 بازه تقسیم شد و تعداد پیکسل‌هایی از تصویر که مقدار سطح خاکستری‌شان در هر بازه قرار می‌گرفت به عنوان ویژگی معرفی شد. بدین ترتیب 25 عدد برای هر تصویر بدست آمد که هر کدام یک ویژگی تلقی می‌شود (مانیکاواساگان و همکاران، 2008). در این تحقیق به دلیل صفر بودن بازه‌های 2 تا 14، از 12 بازه‌ی دیگر استفاده شد (HG1, HG15-25).


2-3- انتخاب ویژگی‌ها

از روش ضریب فیشر (FC)¹² و تحلیل اجزای اصلی (PCA)¹³ برای انتخاب ویژگی‌هایی که بیشترین تأثیر را در دسته بندی و شناسایی ارقام داشتند استفاده شد.

روش ضریب فیشر یک ترکیب خطی از متغیرها را پیدا می‌کند تا بتواند دو دسته را هر چه بهتر توسط یک خط از هم جدا کند. معیاری که توسط فیشر ارائه شده است نسبت واریانس درون دسته‌ای به واریانس بین دسته‌ای است (سبحانی پور، 1390).

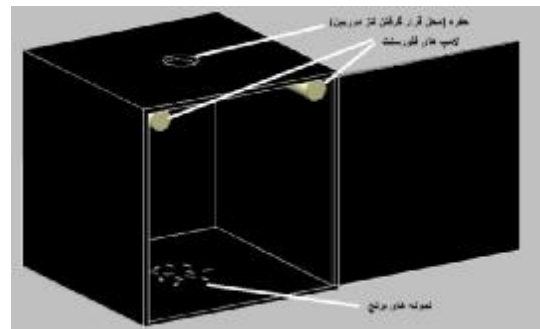
PCA یک روش برای تبدیل داده‌هاست. ایده‌ی اصلی آن، یافتن جهت‌ها یا محورهایی است که در روی این محورها بردارهای ویژه‌ی ماتریس همبستگی داده‌ها حداکثر هستند و سپس یافتن تصویر داده‌ها روی این محورها (اجزای اصلی) و سرانجام نمایش داده‌ها با تعداد کمی از اجزای اصلی که متناظر با مقادیر ویژه‌ی بزرگتری هستند (وکیلی باغمیشه، 2002).

روش ضریب فیشر با استفاده از دستور فیشر فیلترینگ¹⁴ در نرم افزار تاناگرا¹ ویرایش 1/4/45 و روش PCA در نرم افزار متلب² ویرایش 7/7 انجام شد.



شکل 1- تصاویر سه رقم برنج: الف- فجر ب- شیروودی ج- طارم

از یک جعبه مکعبی شکل برای تصویر برداری استفاده شد که داخل آن کاملاً سیاه رنگ بود و درب آن در هنگام تصویر برداری بسته می‌شد تا از انعکاس نور در داخل آن و ایجاد سایه جلوگیری شود. همچنین دو لامپ فلورسنت میله‌ای شکل در دو طرف جعبه و در مجاورت سقف جعبه نصب شد. در قسمت وسط سقف نیز سوراخی وجود داشت که عدسی دوربین در روی آن قرار می‌گرفت و به این ترتیب تصویر برداری بدون هر گونه تداخل نوری از خارج انجام شد. طرحواره سامانه تصویر برداری استفاده شده در شکل 2 نشان داده شده است.



شکل 2- طرحواره سامانه‌ی استفاده شده برای تصویر برداری

2-2- استخراج ویژگی‌ها

در این تحقیق از ویژگی‌های بافتی تصاویر استفاده شده است. بافت یک جنبه‌ی مهم تصویر است و ویژگی‌های بافتی نقش زیادی در تحلیل تصویر دارند (لی و همکاران، 1999). ابتدا تصاویر به روش آستانه‌گیری، قطعه بندی شدند. سپس به هر دانه یک برجسب اختصاص داده شد تا هر دانه از دانه‌های دیگر قابل شناسایی باشد. پس از آن از تصویر مربوط به هر دانه برنج، در مجموع 41 ویژگی بافتی شامل 25 ویژگی از ماتریس سطوح خاکستری (میانگین¹، انحراف معیار، همواری، گشتاور سوم، یکنواختی²، آنتروپی³ (ماجومدار و

¹ - Mean

² - Uniformity

³ - Entropy

⁴ - Histogram Groups

⁵ - Gray Level Co-occurrence Matrix (GLCM)

⁶ - Variance

⁷ - Homogeneity

⁸ - Inertia

⁹ - Cluster Shade

¹⁰ - Cluster Prominence

¹¹ - Maximum Probability

¹² - Local Binary Pattern (LBP)

¹³ - Fisher's Coefficient

¹⁴ - Principal Component Analysis

2-4- شناسایی ارقام

برای شناسایی ارقام برنج در نمونه‌های مخلوط و دسته بندی آنها در سه دسته مختلف از شبکه‌ی عصبی بردار یادگیر چندی ساز (LVQ)⁴ استفاده شد.

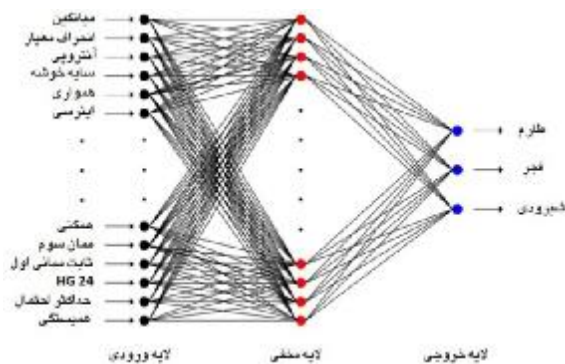
در ابتدا داده‌های موجود بطور تصادفی به دو دسته مجموعه آموزش 80 درصد و مجموعه آزمون 20 درصد کل داده‌ها تقسیم بندی شدند. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را مجدداً تکرار کرد (ژانگ و فوه، 1998). در غیر اینصورت شبکه در طول فاز آموزش همگرا نشده و نتایج مطلوب تولید نخواهد شد (آزاده و همکاران، 2006). برای تبدیل داده‌ها از نرمالیزاسیون خطی بصورت زیر استفاده شد (روحانی و مکاریان 1390):

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times (r_{\max} - r_{\min}) + r_{\min} \quad (1)$$

در اینجا x داده خام اولیه، x_n داده نرمالیزه شده، x_{\max} و x_{\min} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه و r_{\max} و r_{\min} به ترتیب حد بالایی و پایینی دامنه تغییرات داده‌های تبدیل شده است.

نحوه‌ی کار شبکه عصبی LVQ بر اساس تقسیم فضای ورودی R^n به تعدادی منطقه‌های متمایز از هم با نام ناحیه‌های تصمیم‌گیری⁵ و اختصاص یک بردار کد⁶ به هر یک از آنها است. طبقه بندی بر حسب نزدیکی بردار ورودی x به بردارهای کد انجام می‌شود. بردار ورودی متعلق به کلاس نزدیکترین بردار کد خواهد شد. در حال حاضر 6 نسخه الگوریتم آموزش LVQ وجود دارد: LVQ1، LVQ2.1، LVQ3، 0LVQ، CLVQ (کوهسون 1990) و LVQ4 (وکیلی - باغمیشه 2002، و وکیلی - باغمیشه و پاوسیک 2003) که LVQ4 نیز دارای 5 الگوریتم a_1 ، a_2 ، a_3 و c می‌باشد (وکیلی - باغمیشه و پاوسیک 2003). از الگوریتم آموزش LVQ4 به جهت بالا بودن کارایی آن استفاده شد (روحانی و مکاریان، 1390).

ساختار شبکه عصبی LVQ استفاده شده به منظور طبقه بندی ارقام برنج در شکل 3 نشان داده شده است.



شکل 3- ساختار شبکه LVQ استفاده شده برای شناسایی سه رقم برنج طارم، شیرودی و فجر بر اساس ویژگی‌های بافتی معرفی شده در لایه ورودی.

ورودی‌های شبکه ویژگی‌های بافتی استخراج شده از ارقام برنج می‌باشند و خروجی شبکه بردار کدی است که نزدیکترین فاصله اقلیدسی را با ورودی دارد. برچسب بردار کد تعیین کننده دسته بردار ورودی است. برنامه نویسی مدل‌های شبکه‌ی عصبی در محیط نرم افزار متلب نسخه 7/7 انجام شد.

3- نتایج و بحث

نتیجه حاصل از مقایسه‌های آماری در سطح احتمال 5 درصد بین ویژگی‌های استخراج شده از سه رقم برنج مورد مطالعه نشان داد که رقم فجر و طارم بیشترین تفاوت را با یکدیگر دارند؛ زیرا 35 ویژگی از 41 ویژگی آنها با یکدیگر اختلاف معنی‌داری دارند. بنابراین می‌بایست این دو رقم قابلیت تفکیک خوبی داشته باشند. اما تعداد 26 ویژگی در مقایسه رقم‌های فجر - شیرودی و 19 ویژگی در مقایسه رقم‌های طارم - شیرودی معنی‌دار شدند که این امر نشان دهنده‌ی این است که رقم شیرودی شباهت زیادی به دو رقم دیگر بخصوص طارم دارد؛ این امر می‌تواند تفکیک آنها را همراه با اشتباه نماید، به عبارت دیگر، باعث شود که رقم شیرودی به اشتباه به عنوان واریته‌ی طارم یا فجر شناسایی شود و خطای شناسایی رقم شیرودی بالا رود و یا اینکه ارقام طارم و فجر به اشتباه از نوع شیرودی شناسایی شوند و خطای شناسایی این دو رقم بالا رود.

نتایج حاصل از آموزش و آزمایش شبکه عصبی LVQ4 و به کمک روش PCA برای هر رقم و هر گروه ویژگی در جدول 1 ارائه شده است. بالا بودن خطا در مرحله آزمایش نشان می‌دهد که داده‌ها برای شبکه عصبی آموزش دیده کاملاً تازگی دارند و از طرف دیگر در این مرحله هدف نشان دادن قدرت یادگیری شبکه است و هنوز شبکه عصبی به طور کامل بهینه نشده است.

سپس ویژگی‌های مربوط به هر گروه ویژگی، توسط روش FC رتبه بندی شدند. جداول 2، 3، 4 و 5 به ترتیب مقادیر خطا را برای مرحله

¹-Fisher Filtering

²-Tanagra

³- Matlab

⁴- Learning Vector Quantization

⁵-Decision Regions (Voronoi Cells)

⁶-Codebook (Voronoi) Vector

جدول 3- مقادیر درصد خطای شناسایی سه رقم برنج به کمک 100- 30 درصد از ویژگی های برتر انتخابی توسط FC از ماتریس هم وقوعی

درصد انتخاب	30	40	70	80	90	100
تعداد ویژگی	3	4	7	8	9	10
فجر	13/37	8/77	7/07	5/00	2/75	3/74
شیرودی	9/73	7/03	5/99	2/86	2/72	4/65
طارم	5/68	1/69	2/75	2/25	1/20	3/45
خطای شبکه	9/57	5/82	5/25	3/38	2/25	3/94

جدول 4- مقادیر درصد خطای شناسایی سه رقم برنج به کمک 100- 30 درصد از ویژگی های برتر انتخابی توسط FC از ماتریس الگوی

دودویی محلی						
درصد انتخاب	30	50	70	90	100	
تعداد ویژگی	2	3	4	5	6	
فجر	15/00	12/87	9/44	15/17	7/51	
شیرودی	13/48	11/17	14/84	10/34	9/77	
طارم	10/29	6/56	4/09	11/60	5/38	
خطای شبکه	12/95	10/13	9/57	12/38	7/50	

در مورد ماتریس شامل کلیه ویژگی های بافتی نیز بهترین مقادیر خطای آموزش در مورد دو رقم فجر و شیرودی با انتخاب 37 درصد از ویژگی ها یعنی 15 ویژگی حاصل شده است. اما در مورد رقم طارم انتخاب 100 درصد از ویژگی ها منجر به کمترین خطا شده است و به دلیل اینکه در 37 درصد، خطای شبکه و نیز خطای مربوط به رقم های فجر و شیرودی کمترین مقدار می باشد و خطای مربوط به رقم طارم نیز در حد متوسطی قرار دارد، بنابراین 37 درصد ویژگی ها به عنوان مقدار بهینه در نظر گرفته شد و به این ترتیب مقادیر بهینه برای هر نوع ماتریس بدست آمد.

جدول 5- مقادیر درصد خطای شناسایی سه رقم برنج به کمک 100- 20 درصد از ویژگی های برتر انتخابی توسط FC از ویژگی های کلیه

ماتریس ها						
درصد انتخاب	20	37	60	80	90	100
تعداد ویژگی	8	15	25	33	37	41
فجر	8/47	2/23	5/82	7/51	4/55	3/91
شیرودی	3/85	1/71	3/51	6/15	4/47	1/76
طارم	3/45	1/68	4/62	3/87	1/69	1/63
خطای شبکه	5/25	1/88	4/69	5/82	3/56	2/43

جدول 6 مقادیر درصد دقت در دو مرحله آموزش و آزمایش شبکه عصبی LVQ4 به کمک پنج الگوریتم a1، a2، a3، a4 و c (وکیلی باغمیسه 2003) را نشان می دهد. با تنظیمات یکسان برای همه الگوریتم ها نتایج این جدول نشان می دهد که در مورد ماتریس

جدول 1- مقادیر درصد دقت شناسایی سه رقم برنج در دو مرحله آموزش و آزمایش شبکه عصبی

		فجر	شیرودی	طارم
ماتریس سطوح خاکستری	مرحله آموزش	94/29	97/27	98/86
	مرحله آزمایش	87/23	74/36	89/36
ماتریس هم وقوعی	مرحله آموزش	94/44	97/21	97/13
	مرحله آزمایش	76/19	86/05	85/42
ماتریس الگوی دودویی محلی	مرحله آموزش	92/15	95/18	95/45
	مرحله آزمایش	80/65	71/43	93/48
ماتریس کلیه ویژگی های بافتی	مرحله آموزش	95/00	95/48	97/73
	مرحله آزمایش	76/19	84/44	91/30

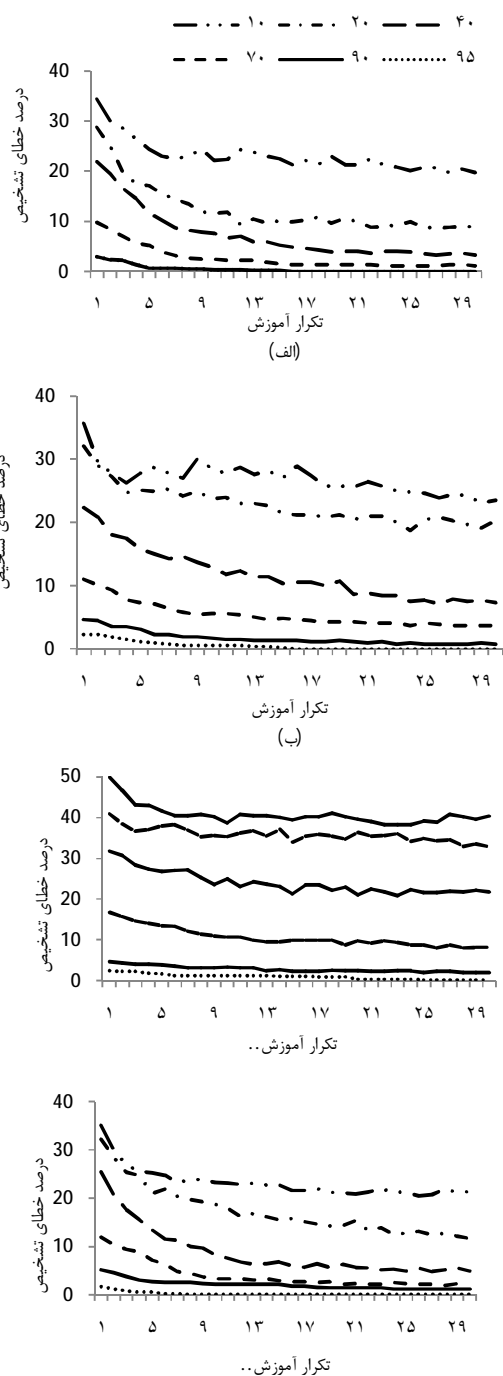
آموزش شبکه عصبی بر حسب درصد انتخاب ویژگی های برتر رتبه بندی شده توسط روش FC از ماتریس سطوح خاکستری، ماتریس هم وقوعی، ماتریس الگوی دودویی محلی و ماتریس شامل کلیه ویژگی های بافتی نشان می دهند. همانطور که ملاحظه می شود با استفاده از ویژگی های ماتریس سطوح خاکستری، در مورد دو رقم شیرودی و فجر با افزایش تعداد ویژگی ها تا 80 درصد از کل ویژگی ها، مقادیر خطای آموزش جهت یادگیری کاهش می یابد. اما در مورد رقم طارم، انتخاب 60 درصد از ویژگی ها منجر به کمترین خطا شده است و به دلیل اینکه در 80 درصد، خطای شبکه نیز کمترین مقدار می باشد، بنابراین 80 درصد ویژگی ها به عنوان مقدار بهینه در نظر گرفته شده است (خطای شبکه از تقسیم تعداد کل نمونه هایی که در آخرین تکرار مرحله آموزش به اشتباه طبقه بندی شده اند به تعداد کل نمونه های ورودی به این مرحله و ضرب حاصل تقسیم در عدد 100 بدست آمده است).

در ماتریس هم وقوعی، بهترین مقادیر خطای آموزش و نیز خطای شبکه با انتخاب 90 درصد از ویژگی ها حاصل می شود، بنابراین 90 درصد ویژگی ها به عنوان مقدار بهینه در نظر گرفته شد.

در ماتریس الگوی دودویی محلی، بهترین مقادیر خطای آموزش در مورد دو رقم شیرودی و فجر با انتخاب صد در صد از ویژگی ها یعنی 6 ویژگی حاصل شده است. اما در مورد رقم طارم، انتخاب 70 درصد از ویژگی ها منجر به کمترین خطا شده است و به دلیل اینکه در 100 درصد، خطای شبکه و نیز خطای شناسایی شیرودی و فجر کمترین مقدار می باشد و خطای مربوط به رقم طارم نیز در حد متوسطی قرار دارد، بنابراین 100 درصد ویژگی ها به عنوان مقدار بهینه در نظر گرفته شد.

جدول 2- مقادیر درصد خطای شناسایی سه رقم برنج به کمک 100-20 درصد از ویژگی های برتر انتخابی توسط FC از ماتریس سطوح خاکستری

درصد انتخاب	20	40	60	80	90	100
تعداد ویژگی	5	10	15	20	23	25
فجر	21/18	6/01	4/92	3/38	3/98	4/47
شیرودی	14/12	1/14	2/32	1/12	2/78	1/85
طارم	12/90	2/30	0/56	1/12	2/26	1/56
خطای شبکه	15/95	3/19	2/63	1/88	3/00	2/63



شکل 4- نمودار همگرایی شبکه عصبی بر حسب افزایش درصد بردارهای کد (الف) ماتریس سطوح خاکستری، (ب) ماتریس هم وقوعی، (ج) ماتریس الگوی دودویی محلی، (د) ماتریس کلیه ویژگی های بافتی

شکل 4 نمودار همگرایی شبکه عصبی با استفاده از ویژگی های ماتریس سطوح خاکستری (الف)، ماتریس هم وقوعی (ب)، ماتریس

سطوح خاکستری و ماتریس شامل کلیه ویژگی های بافتی، LVQ4a3 و LVQ4a4 و در مورد ماتریس هم وقوعی و ماتریس الگوی دودویی محلی، LVQ4a3 می تواند بهترین گزینه ها جهت شناسایی ارقام برنج مورد مطالعه باشد.

جدول 6- مقادیر درصد دقت طبقه بندی انواع الگوریتم های LVQ4 به

کمک روش FC-PCA				
c	a4	a3	a2	a1
62/48	97/56	97/56	97/37	93/25
62/41	81/20	81/20	81/20	76/69
55/91	92/50	93/43	93/06	87/80
56/39	79/70	79/70	79/70	72/18
49/34	78/99	80/49	79/36	78/99
38/35	64/66	66/17	64/66	62/41
70/73	96/62	97/00	96/62	90/24
69/17	84/96	83/46	84/21	78/20

نتایج دسته بندی سه رقم برنج بر اساس روش دسته بندی ویژگی ها توسط روش فیشر (FC)، تحلیل اجزای اصلی (PCA) و ترکیب FC-PCA به کمک شبکه عصبی LVQ4 در 50 تکرار از الگوریتم آموزش و با تعداد بردارهای کد به اندازه 50 درصد از تعداد عضوهای هر دسته در جدول 7 آمده است. در مورد روش FC، ابتدا کلیه ویژگی های مربوط به هر ماتریس توسط FC رتبه بندی شدند و سپس دسته بندی با 50 درصد ویژگی اول رتبه بندی شده انجام شد. در مورد روش FC-PCA از همین 50 درصد ویژگی اول دسته بندی شده توسط FC استفاده شد و سپس روش PCA بر روی آن ها اعمال شد. در روش PCA نیز از کلیه ویژگی ها استفاده شد. نتایج ماتریس سطوح خاکستری نشان می دهد که روش PCA نسبت به دو روش دیگر یعنی FC و FC-PCA منجر به خطای کمتری در مرحله آموزش و آزمایش LVQ4 شده است و در مورد ماتریس هم وقوعی و الگوی دودویی محلی و ماتریس شامل کلیه ویژگی های بافتی، استفاده از روش فیشر منجر به خطای کمتری در مرحله آموزش و آزمایش شبکه عصبی شده است.

جدول 7- مقادیر درصد دقت طبقه بندی LVQ4 به کمک سه روش

FC و PCA و FC-PCA		
FC-PCA	FC	PCA
97/19	33/40	98/12
83/46	33/08	84/21
94/37	96/25	93/81
25/56	79/70	76/69
86/12	88/93	83/30
63/16	75/19	66/17
94/00	98/50	97/56
78/20	81/20	81/20

همانطور که دیده می‌شود، شبکه‌ی عصبی در مورد ماتریس سطوح خاکستری (شکل 5-الف) پس از 16 تکرار، در مورد ماتریس هم وقوعی (شکل 5-ب) پس از 16 تکرار، در مورد ماتریس الگوی دودویی محلی (شکل 5-ج) پس از 25 تکرار و در مورد ماتریس شامل کلیه‌ی ویژگی‌های بافتی (شکل 5-د) پس از 8 تکرار مجموعه داده‌های آموزش را به طور کامل یادگرفته و مقدار خطا به صفر رسیده یا به صفر کاملاً نزدیک شده است (ماتریس الگوی دودویی محلی)؛ یعنی شبکه‌ی عصبی LVQ4 به خوبی توانسته است سه رقم برنج فجر، طارم و شیرودی را بر اساس گروه‌های مختلف ویژگی بافتی از یکدیگر تشخیص داده و تفکیک نماید. بنابراین مرحله آموزش شبکه‌ی عصبی به اتمام می‌رسد.

وجود مقدار بسیار کم خطا در مرحله‌ی آموزش شبکه‌ی عصبی با استفاده از ویژگی‌های ماتریس الگوی دودویی محلی می‌تواند مربوط به کمتر بودن ویژگی‌های این ماتریس نسبت به سه ماتریس دیگر باشد که باعث شده است شبکه به خوبی آموزش نبیند و مقدار کمی خطا باقی بماند.





سپس پارامترهای بهینه‌ی حاصل از مراحل قبلی در نظر گرفته شد و نتیجه‌ی نهایی که دقت طبقه بندی سه رقم طارم، فجر و شیرودی می‌باشد بدست آورده شد که نتایج حاصل در جدول 8 نشان داده شده است. چون دقت طبقه بندی در مرحله آزمایش بالا می‌باشد لذا پارامترهای شبکه به خوبی بهینه شده‌اند. همانطور که در جدول 8 دیده می‌شود، استفاده از کلیه‌ی ویژگی‌های بافتی منجر به خطای طبقه بندی کمتری شده است، چنانکه که پوررضا و همکاران (2012) نیز بالاترین دقت طبقه بندی واریته های گندم را با استفاده از کلیه‌ی ویژگی‌های بافتی بدست آوردند. نتایج مقایسات آماری نشان دهنده آن است که استفاده از ویژگی‌های این ماتریس، خطای شناسایی رقم شیرودی را نسبت به دو رقم دیگر افزایش می‌دهد. علاوه بر آن در مقایسه با تحقیقات پیشین (ماجومدار و جایاس، 2000، و موسوی راد و همکاران، 2011)، روش استفاده شده در این تحقیق دقت دسته‌بندی بالاتری داشته است. از آنجایی که زمان صرف شده برای دسته‌بندی به تعداد تکرار آموزش بستگی دارد، بنابراین در مورد ماتریس شامل کلیه‌ی ویژگی‌های بافتی که شبکه در 8 تکرار آموزش همگرا شده است، زمان صرف شده از بقیه موارد کمتر بوده است. در نتیجه استفاده از کلیه‌ی ویژگی‌های بافتی هم از نظر دقت و هم از نظر زمان دسته‌بندی نسبت به موارد دیگر (ویژگی‌های ماتریس سطوح خاکستری، ماتریس هم وقوعی و ماتریس الگوی دودویی محلی) برتری داشته است.

جدول 8: مقادیر درصد دقت طبقه‌بندی سه رقم برنج

طارم	شیرودی	فجر		
100/00	100/00	100/00	مرحله آموزش	ماتریس سطوح خاکستری
97/83	100/00	97/96	مرحله آزمایش	
100/00	100/00	100/00	مرحله آموزش	ماتریس هم وقوعی
100/00	100/00	96/23	مرحله آزمایش	
100/00	99/45	100/00	مرحله آموزش	ماتریس الگوی دودویی محلی
100/00	97/50	100/00	مرحله آزمایش	
100/00	100/00	100/00	مرحله آموزش	ماتریس کلیه ویژگی‌های بافتی
100/00	97/67	100/00	مرحله آزمایش	

الگوی دودویی محلی (ج) و ماتریس شامل کلیه‌ی ویژگی‌های بافتی (د) با الگوریتم انتخاب شده برای هر مورد را به ازای مقادیر درصد انتخاب بردارهای کد از فضای ورودی نشان می‌دهد.

نتایج این شکل نشان می‌دهد که هر اندازه درصد انتخاب بردارهای کد از فضای نمونه‌های ورودی بیشتر باشد، دقت شناسایی افزایش و خطای آن کاهش می‌یابد. این در حالی است که تعداد تکرارهای آموزش نیز کمتر می‌شود، لذا زمان آموزش کاهش می‌یابد. بنابراین در این مطالعه مقدار 95 درصد برای ماتریس‌های هم وقوعی، الگوی دودویی محلی و ماتریس شامل کلیه‌ی ویژگی‌های بافتی و مقدار 90 درصد برای ماتریس سطوح خاکستری به عنوان تعداد بردارهای کد از فضای نمونه ورودی انتخاب گردید.



شکل 5- نمودار همگرایی شبکه عصبی LVQ4، q تعداد تکرار آموزش و $R.E.$ درصد خطای طبقه بندی (الف) ماتریس سطوح خاکستری، (ب) ماتریس هم وقوعی، (ج) ماتریس الگوی دودویی محلی، (د) ماتریس کلیه ویژگی‌های بافتی

شکل 5 نمودار همگرایی شبکه را پس از پیدا کردن مقادیر بهینه پارامترهای شبکه از طریق آزمون و خطا نشان می‌دهد.

4- نتیجه گیری نهایی

100 و 97/83 درصد؛ ماتریس هم وقوعی 100/96/23 و 100 درصد؛ ماتریس الگوی دودویی محلی 100، 97/50 و 100 درصد و با استفاده از کلیه ویژگی‌های ماتریس‌ها 100، 97/67 و 100 درصد بود. این نتایج نشان می‌دهند که استفاده از کلیه ویژگی‌ها منجر به خطای طبقه بندی کمتری شده است، بنابراین استفاده از آن پیشنهاد می‌شود.

این تحقیق نشان داد که تکنیک‌های پردازش تصویر می‌توانند با تکنیک‌های دسته‌بندی توسط شبکه‌های عصبی مصنوعی ترکیب شوند تا دانه‌های برنج را در نمونه‌های مخلوط شناسایی و دسته‌بندی کنند. دقت طبقه بندی LVQ4، به ترتیب برای سه رقم فجر، شیروودی و طارم با استفاده از ویژگی‌های ماتریس سطوح خاکستری 97/96،

منابع مورد استفاده

- بی‌نام- 1390. آمارنامه کشاورزی، جلد اول: محصولات زراعی، مرکز فناوری اطلاعات و ارتباطات وزارت جهاد کشاورزی، 90-1389.
- روحانی، ع.، ح. مکاریان - 1390. تهیه نقشه‌های مدیریتی علف هرز با استفاده از شبکه‌های عصبی مصنوعی با هدف کاربرد در کشاورزی دقیق، نشریه‌ی ماشین‌های کشاورزی، شماره 1، صفحه 74-83.
- سبحانی پور، س. ر. - 1390. تشخیص عیوب سطحی عناب و طبقه‌بندی آن به کمک پردازش تصویر، پایان‌نامه‌ی کارشناسی ارشد، دانشکده‌ی کشاورزی، دانشگاه فردوسی مشهد.
- کیا، س. م. - 1386. پردازش تصاویر دیجیتال در MATLAB، (ترجمه)، نشر کیان، تهران.
- موسوی‌راد، س. ج.، ف. اخلاقیان‌تاب، و ک. ملازاده - 1390. دسته بندی ارقام برنج با استفاده از ویژگی‌های بهینه رنگ و بافت و شبکه‌های عصبی پس انتشار، هفتمین کنفرانس ماشین بینایی و پردازش تصویر ایران، 26-25 آبان 1390، تهران.
- Azadeh, A.S., F. Ghaderi, and S. Sohrabkhani. 2006. *Forecasting electrical consumption by integration of neural network, time series and ANOVA*. Applied Mathematics and Computation. 186: 1753-1761.
- Chen, X. J., D. Wu, Y. He and S. Liu. 2009. *Study on application of multi-spectral image texture to discriminating rice categories based on wavelet packet and support vector machine*. Spectroscopy and Spectral Analysis., 29(1): 222-225.
- Haralick, R. M., K. Shanmugam, and I. Dinstein. 1973. *Textural features for image classification*. IEEE Transactions on Systems, Man, and Cybernetics., 3(6): 610-621.
- Kohonen, T. 1990. *The Self-Organizing Map*. Proceedings of IEEE. 78(9).
- Kohonen, T. 1995. *Self-organizing map*. Springer-Verlag. Berlin. Heidelberg.
- Li, J., J. Tan, F. A. Martz, and H. Heymann. 1999. *Image texture features as indicators of beef tenderness*. Meat Science., 53(1): 17-22,
- Majumdar, S., and D. S. Jayas. 1999. *Classification of bulk Samples of cereal grains using machine vision*. Journal of Agricultural Engineering Research. 73(1): 35-47.
- Majumdar, S., and D. S. Jayas. 2000. *Classification of cereal grains using machine vision: III. Texture models*. Transactions of the ASAE. 43(6): 1681-1687.
- Manickavasagan, A., G. Sathya, D. S. Jayas and N. D. G. White. 2008. *Wheat class identification using monochrome images*. Journal of Cereal Science, 47(3): 518-527.
- Park, B. and Y. R. Chen. 2001. *Co-occurrence matrix texture features of multi-spectral images on poultry carcasses*. Journal of Agricultural Engineering Research., 78(2): 127-139.
- Pour reza, A., H. R. Pour reza, M. H. Abbaspour-Fard, and H. Sadrnia. 2012. *Identification of nine Iranian wheat seed varieties by textural analysis with image processing*. Computers and Electronics in Agriculture., 83: 102-108.
- Vakil-Baghmisheh, M. T. 2002. *Farsi character recognition using artificial neural networks*, Ph.D. Thesis. Faculty of Electrical Engineering. University of Ljubljana.

- Vakili-Baghmisheh, M. T., and N. Pavesic. 2003. *Premature clustering phenomenon and new training algorithms for LVQ*. Pattern Recognition. 36: 1901-1921.
- Zapotoczny, P. 2011. *Discrimination of wheat grain varieties using image analysis and neural networks. Part I. Single kernel texture*. Journal of Cereal Science. 54(1): 60-68.
- Zhang, Y. F., and J. Y. H. Fuh. 1998. *A neural network approach for early cost estimation of packaging products*. Computers and Industrial Engineering. 34: 433-50.

Identification of three Iranian Rice Grain Varieties in Mixed Bulks Using Different Textural Features and LVQ Neural Network

Saeideh fayyazi^{1*}, Mohammad Hossein Abbaspour-Fard², S. Amirhassan Monadjemi³, Hassan Sadrnia⁴ and Abbas Rohani⁵

¹Dept. of Agricultural Machinery Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad, Iran

²Dept. of Agricultural Machinery Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad, Iran

³Dept. of Computer Engineering, Faculty of Engineering, University of Isfahan, Iran

⁴Dept. of Agricultural Machinery Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad, Iran

⁵Dept. of Agricultural Machinery Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad, Iran

*Corresponding author: E-mail:Fayyazi_s@yahoo.com

Abstract

Due to variation in economic value of different rice varieties, reports indicate the possibility of mixing different varieties on the market. Applying machine vision techniques to classify rice varieties is a method which can increase the accuracy of classification process in real world applications. In this study, several textural feature groups of rice grains' images were examined to evaluate their efficacy in identification of three Iranian rice varieties (Tarom, Fajr, Shiroodi) in the mixed samples of these three varieties. On the whole, 666 images of rice grains (222 images of each variety) were acquired at a stable illumination condition and totally, 41 textural features were extracted from different matrices of grain images. Fisher's coefficient method, Principal Component Analysis method and a combination of these two methods were employed to rank and select the most significant features for the classification. The so called LVQ4 neural network classifier was employed for classification using top selected features. The classification accuracy of 97.96, 100 and 97.83 percent by using gray level matrix, 96.23, 100 and 100 percent by using co-occurrence matrix, 100, 97.50 and 100 percent by using local binary pattern matrix, and 100, 97.67 and 100 percent by using the whole textural features were obtained for Fajr, Tarom and Shiroodi, respectively. These results indicate that image processing can be a suitable tool for identification of different rice varieties. Although using the features of all matrices leads to less classification error, the features of each matrix also provides reasonable accuracy.

Keywords: Image processing, Neural network, Rice, Textural features