

## مقاله پژوهشی

### تعیین درصد خرده برنج در توده با واکاوی ویژگی‌های تصویر

سید مهدی نصیری<sup>۱\*</sup>، میثم شفیع<sup>۲</sup>، عبدالعباس جعفری<sup>۳</sup> و داریوش زارع<sup>۴</sup>

#### چکیده

روش رایج اندازه‌گیری و محاسبه مقدار خرده برنج در یک توده، جداسازی و توزین برنج‌های سالم و شکسته است. جداسازی دانه‌های برنج به وسیله الک یا به صورت دستی انجام می‌شود که انجام این کار نیازمند صرف وقت و نمونه‌گیری دوره‌ای است. در این مطالعه برخی ویژگی‌های بافت تصویر توده برنج برای تعیین درصد خرده برنج در آن مورد بررسی قرار گرفت. برای این منظور، ۲۱ نمونه ۱۰۰ گرمی حاوی درصدهای متفاوت برنج خرده از ترکیب برنج سالم و خرده برنج (شامل صفر تا ۱۰۰ درصد خرده) تهیه شد. از هر نمونه تعداد ۱۰ تصویر از توده تهیه شد. با پیش پردازش تصاویر، نوفه و پس زمینه حذف شد و تصاویر از حالت رنگی به دودویی تبدیل شدند و با استفاده از نرم‌افزار MATLAB ویژگی‌های بافت تصاویر استخراج شد. تعداد ۲۳ ویژگی بافتی از تصاویر نمونه‌های برنج با روش ماتریس هم‌رخداد سطح خاکستری استخراج شد. کاهش تعداد ویژگی‌های بافت تصویر با تحلیل مؤلفه‌های اصلی انجام شد. با این روش ۲۳ ویژگی محاسبه شده با ۳ عامل اصلی (متغیر پنهان) مرتبط شد. رابطه بین درصد خرده برنج در نمونه‌ها با ویژگی‌های بافتی مستخرج از تصاویر با روش شبکه عصبی مصنوعی با ورودی ویژگی‌های بافتی (عامل‌های اصلی) و خروجی درصد برنج خرد شده بررسی گردید. داده‌ها به چهار شبکه عصبی با توپولوژی متفاوت از نظر تعداد نرون‌ها در دولایه مخفی وارد و خروجی آن مورد بررسی قرار گرفت. نتایج حاصل از خروجی شبکه‌های عصبی بررسی شده نشان داد شبکه عصبی با ساختار ۱-۸-۶-۳ با ضریب تبیین ۰/۹۵۷۵ توانست مقدار خرده برنج (درصد) در یک توده را با خطای کل ۱/۵ درصد تشخیص دهد. افزون بر آن، مشخص شد ده ویژگی بافت تصویر مرتبط با عامل اصلی اول، چهار ویژگی مرتبط با عامل اصلی دوم، چهار ویژگی مرتبط با عامل اصلی سوم و پنج ویژگی بافت هم به صورت مشترک وابسته با عامل‌های اصلی اول و دوم بودند. هشت ویژگی با ضریب عاملی بالاتر از ۰/۹ مرتبط با عامل اول و سوم بیشترین تأثیر را در تخمین درصد خرده برنج داشته‌اند. این روش تعیین درصد خرده برنج نسبت به نوع مرسوم (دستی) آن سریع است و قابلیت برخط شدن را دارد.

**واژه‌های کلیدی:** برنج، خرده برنج، پردازش تصویر، تحلیل مولفه‌های اصلی، شبکه عصبی، ویژگی‌های بافت تصویر

**ارجاع:** نصیری س. م.، شفیع م.، عبدالعباس جعفری ع. و زارع د. ۱۴۰۰. تعیین درصد خرده برنج در توده با واکاوی ویژگی‌های تصویر. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۱۹: ۵۷-۶۶.

۱- دانشیار گروه مهندسی بیوسیستم، دانشگاه شیراز.

۲- دانشجوی سابق کارشناسی ارشد، گروه مهندسی بیوسیستم، دانشگاه شیراز.

۳- دانشیار گروه مهندسی بیوسیستم، دانشگاه شیراز.

۴- دانشیار گروه مهندسی بیوسیستم، دانشگاه شیراز.

\* نویسنده مسئول: [nasiri@shirazu.ac.ir](mailto:nasiri@shirazu.ac.ir)

تاریخ پذیرش: ۱۳۹۹/۱۰/۰۸

تاریخ دریافت: ۱۳۹۹/۰۱/۱۸

## مقدمه

برنج (*Oryza sativa* L.) از خانواده گرامینه، گیاه یک ساله و موطن اصلی آن اندونزی است. قدیمی‌ترین گیاهی است که برای استفاده از دانه آن کشت داده می‌شود و یکی از اقلام پر مصرف مواد غذایی در ایران و جهان است. این محصول کشاورزی غذای بیش از نیمی از مردم جهان را تأمین می‌کند (Courtois et al., 2001). علی‌رغم دشواری‌های موجود در تولید برنج حجم قابل توجهی از آن به دلایل مختلف از مرحله کاشت تا مرحله مصرف به هدر می‌رود. در کشورهای در حال توسعه حدود ۳۰ تا ۴۰ درصد از کل محصول تولیدی کشاورزی در مراحل مختلف فرآوری شامل آسیاب، خشک کردن، نگهداری، حمل و نقل و تبدیل دچار ضایعات می‌شود (Nassiri et al., 2019). تحقیقات نشان می‌دهد که در بازارهای جهانی در صورت وجود خرده برنج در محصول عرضه شده برای فروش، قیمت آن با توجه به شرایط تا ۱۰ درصد برنج مرغوب کاهش می‌یابد (Courtois et al., 2010).


در میان غلات، برنج تنها محصولی است که شکل ظاهری و درصد شکستگی در آن عامل مهمی به شمار می‌رود. در حال حاضر بسیاری از سامانه‌های جدایش و درجه‌بندی محصولات کشاورزی از سوی انسان و بر اساس قضاوت‌های انسانی است و درجه‌بندی دستی در بسیاری از موارد سبب اشتباه در درجه‌بندی محصول می‌شود. در صورت عدم تمرکز عامل انسانی حتی در یک مدت‌زمان کوتاه، امکان عدم تشخیص بخشی از محصولات آسیب‌دیده وجود دارد. کنترل کیفیت محصولات در سامانه مبتنی بر بینایی رایانه‌ای می‌تواند تضمین کند که از کل بازه زمانی برای بررسی محصولات استفاده شود (Bato et al., 1999; Dalen, 2004).

اهمیت مقوله پردازش تصاویر در کنترل کیفیت بدین جهت است که تعیین کیفیت مواد غذایی به این روش به‌صورت راحت‌تر و سریع‌تر ممکن است. اساس تعیین کیفیت مواد غذایی در سامانه پردازش تصویر خواص ظاهری مانند رنگ و ویژگی‌های ریخت‌شناسی است. این سامانه دارای هزینه پایین و پاسخ‌گویی سریع و دقیق است (Majumdar & Jayas, 2000; Pourreza et al., 2012). Pourreza et al. (2012) از گروه‌های مختلف ویژگی‌های بافتی برای شناسایی ۹ رقم گندم ایرانی استفاده کردند و

بالاترین دقت شناسایی را با استفاده از کلیه ویژگی‌های بافتی به دست آوردند.

در سال‌های اخیر پژوهش‌هایی برای کیفیت‌سنجی و درجه‌بندی برنج با استفاده از فناوری بینایی ماشین انجام شده است. Liu et al. (2005) روشی را برای طبقه‌بندی شش رقم شلتوک با استفاده از ویژگی‌های رنگ و شکل ارائه دادند. در این مطالعه هفت ویژگی رنگی و چهار ویژگی شکلی از هر دانه شلتوک استخراج شد و با استفاده از همبستگی بین ویژگی‌ها، ۱۷ ویژگی به عنوان ویژگی‌های برتر معرفی شد. دقت این روش ۸۸/۳ درصد گزارش شد. (Mallah (2013) با لحاظ کردن ویژگی‌های شکل و طول جداسازی خرده برنج را با خطای ۱/۲ تا ۲/۵ درصد به انجام رساند. (Chen et al. (2009) از ویژگی‌های بافتی تصاویر چند طیفی برای تفکیک ارقام برنج بر مبنای گروه موجک و ماشین بردار پشتیبان استفاده کردند. نتایج به‌دست‌آمده مفید بودن این روش را نشان داد. ویژگی ابعادی برنج با کمک پردازش تصویر برای تعیین مقدار خرده برنج مورد استفاده قرار گرفت که نتایج قابل قبولی حاصل شد اما درباره دقت این روش چیزی گزارش نشد (Aghayeghazvini et al., 2012). Zapotoczny (2011) از تحلیل تصویر بر مبنای ویژگی‌های بافتی برای تفکیک ارقام گندم از شبکه‌های عصبی استفاده کرد و درستی دسته‌بندی ۱۰۰ درصد برای ۱۱ رقم گندم به دست آمد. (Aulakh & Banga (2012) یک الگوریتم پردازش تصویر را در محیط نرم‌افزار MATLAB برای تعیین عملکرد برنج سالم برای برنج قهوه‌ای انجام دادند. در این روش چنین فرض شد که دانه‌های شکسته در مقایسه با دانه‌های سالم تعداد پیکسل کمتری را به خود اختصاص می‌دهند. بر همین اساس یک مقدار آستانه برای تعداد پیکسل‌های مربوط به دانه‌های سالم به دست آمد و دانه‌هایی که تعداد پیکسل مربوط به ناحیه آن‌ها از مقدار آستانه کمتر بود از تصویر حذف شدند. در انتها عملکرد برنج سالم با تقسیم تعداد دانه‌های باقیمانده در تصویر دوم بر تعداد کل دانه‌ها در تصویر اول محاسبه شد. (Pabamalie & Premaratne (2011) ویژگی‌های ماتریس هم‌رخدادی و رنگی را از تصاویر ارقام مختلف برنج استخراج نمودند و با استفاده از یک شبکه عصبی دسته‌بندی را انجام دادند. دقت بین ۶۸٪ تا ۹۴٪ برای ۴ رقم مختلف برنج حاصل این پژوهش بود.

خطا و افزایش دقت در آموزش الگوریتم و محاسبات از یک رقم برنج کاملاً سالم و خرده برنج جداشده همان رقم استفاده شد. پس از سه مرتبه جداسازی به روش دستی و چشمی خرده برنج‌ها از برنج سالم، نمونه‌های ۱۰۰ گرمی با درصد وزنی مختلف از برنج سالم و برنج خرد شده ترکیب شدند (جدول ۱). سپس از توده محصول عکس-برداری صورت گرفت. از آنجا که در این روش تصویر توده محصول شامل تعداد بسیار زیادی دانه در وضعیت‌های ممکن از هم‌پوشانی است، ویژگی استخراج شده از تصاویر، شاخصی از کل وضعیت اختلاط دانه‌ها را نشان خواهد داد. برای تصویربرداری از یک دوربین عکاسی دیجیتال DSLR مدل Nikon D40 با وضوح ۶/۱ مگاپیکسل (۳۰۰۰×۲۰۰۰ پیکسل) استفاده شد که در ارتفاع ۴۰ سانتی‌متری بالای نمونه‌های مورد آزمایش قرار گرفت. ارتفاع، محل قرارگیری و حالت نمای نزدیک دوربین برای همه تصاویر ثابت بود. سرعت شاتر و دیافراگم به ترتیب ۱/۸۰ و ۳/۲ تنظیم شد به نحوی که کیفیت تصویر بدست آمده برای همه نمونه‌ها یکسان باشد. برای تهیه عکس‌ها از اتاقک نورپردازی و عکس‌برداری با تابش نور غیرمستقیم استفاده شد (شکل ۱). این اتاقک با قطر ۶۰ سانتی‌متر و یک سکو در مرکز به ارتفاع ۹ سانتی‌متر با چهار عدد لامپ هالوژن با منبع برق مستقیم شرایط یکسانی را از لحاظ شدت نور برای همه نمونه‌ها فراهم آورد.



شکل ۱- اتاقک عکس‌برداری

برای افزایش کیفیت عکس‌ها، کاهش نوفه و ایجاد شرایط یکسان، همه تصاویر با استفاده از یک پس‌زمینه با رنگ مشکی و مشخص گرفته شدند. از هر یک از نمونه‌ها ۱۰ تصویر گرفته شد. در هر بار عکس گرفتن دانه‌های نمونه برنج به هم زده شدند تا تصاویر تهیه شده نمونه‌ای از اختلاط دانه‌های شکسته شده و سالم در سطح و عمق


(Pazoki et al. (2014) برای طبقه‌بندی پنج رقم برنج ایرانی ۲۴ ویژگی رنگی، ۱۱ ویژگی مورفولوژیکی و ۴ عامل شکل از تصاویر رنگی هر دانه برنج استخراج کردند. سپس دانه‌های برنج توسط شبکه‌های پرسپترون و عصبی فازی طبقه‌بندی شدند. دقت طبقه‌بندی پنج رقم برنج براساس شبکه عصبی پرسپترون و عصبی فازی به ترتیب ۹۹/۴۶ و ۹۹/۷۳ درصد گزارش شد. (Sumaryanti et al. (2015) استفاده از شش ویژگی رنگی، چهار ویژگی مورفولوژی و دو ویژگی بافت تصاویر تهیه شده از ارقام مختلف برنج توانستند با ضریب تعیین ۰/۷۰ تشخیص برخی ارقام را به انجام رسانند، اما این روش برای همه ارقام موفق عمل نکرد. (Gudipalli et al. (2016) نیز ویژگی‌های مختلف مورفولوژی، بافتی و رنگی، روش‌های مختلف پیش‌پردازش و روش‌های مدل‌سازی برای دسته‌بندی و تشخیص برنج را مرور کردند. در این مقاله مروری حداقل میانگین دقت ۴۶ درصد تا ۹۸/۸ درصد برای پژوهش‌های پیشین گزارش شد. بر اساس گزارش Pourdarbani et al. (2019) استفاده از ترکیب الگوریتم شبکه عصبی و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) به عنوان روش کاهش ویژگی‌های استخراج شده توانستند دقت دسته‌بندی پنج رقم مختلف خود را با ۹۸/۰۸ درصد به انجام برسانند. (در مطالعات گزارش شده با توجه هدف‌ها و روش‌شناسی پژوهش پردازش و تحلیل عاملی بر روی ویژگی‌های استخراجی صورت نگرفته بود و کل اطلاعات ویژگی‌ها مورد استفاده قرار گرفته بود.

در اکثر تحقیقات انجام شده روی برنج با روش پردازش بافت تصویر، تمرکز محققان بر تشخیص ارقام مختلف برنج از یکدیگر بوده است و برای اندازه‌گیری مقدار برنج خرد شده در توده محصول تحقیق مناسبی صورت نگرفته است. در این مطالعه با استفاده از روش ماتریس هم‌رخداد تعیین بافت تصاویر دیجیتال، میزان خرده برنج در توده محصول تعیین شد و نتایج حاصل با نتایج روش دستی درجه‌بندی مقایسه شد.

## مواد و روش‌ها

### آماده‌سازی نمونه برنج

از رقم برنج صدری هاشمی تعداد ۲۱ نمونه برنج ۱۰۰ گرمی برای این پژوهش استفاده شد. برای کم‌کردن میزان



شکل ۲- الف) تصویر برش داده شده، ب) تصویر در فضای خاکستری

تعداد ۲۳ ویژگی استخراج شده از تصاویر (جدول ۲) برای هر تصویر محاسبه شد (Faraji *et al.*, 2016; Zhang *et al.*, 2017). ماتریس همبستگی بین ۲۳ ویژگی استخراج شده از تصاویر برای بررسی رابطه یا عدم رابطه بین ویژگی‌ها محاسبه شد. در تحلیل عاملی ویژگی‌های هم گروه برای تعیین عامل اصلی بکار می‌روند و محاسبه این ماتریس ضروری است. با مقادیر ماتریس و محاسبه ضریب KMO<sup>۲</sup> (معادله (۱)) ویژگی‌های نهایی برای تحلیل عاملی مشخص شدند. مقدار این ضریب بین صفر و یک است و به عنوان معیار انتخاب تعداد متغیرهای (ویژگی‌های) نهایی برای تحلیل عاملی و در نهایت مدل سازی مورد استفاده قرار گرفت (DeCoster, 1998).

$$KMO = \left[ \frac{\sum \sum r_{ij}^2}{\sum \sum r_{ij}^2 + \sum \sum a_{ij}^2} \right] \quad (1)$$

$r_{i,j}$ : ضریب همبستگی ساده بین متغیر  $i$  و  $j$

$a_{i,j}$ : ضریب همبستگی جزئی بین متغیر  $i$  و  $j$

در صورتی که مقدار KMO کمتر از ۰/۵ باشد متغیر برای تحلیل عاملی مناسب نخواهند بود، بین ۰/۵ تا ۰/۶۹ با احتیاط می‌توان به تحلیل عاملی پرداخت، و در صورتی که مقدار آن بزرگ‌تر از ۰/۷ باشد، همبستگی‌های موجود در بین داده‌ها برای تحلیل عاملی مناسب خواهد بود (Zare & Chahoki, 2014). ویژگی‌های نهایی به عنوان متغیر (یا داده اندازه‌گیری شده) برای تحلیل عاملی استفاده شد. همان‌طور که در شکل ۳ نشان داده شده است عامل‌ها به متغیرها مرتبط هستند و واریانس متغیرها را تبیین می‌کنند. در عین حال بخشی از واریانس متغیرها ممکن است توسط عامل‌های پنهان دیگر (به طور مستقیم) که در محاسبات در نظر گرفته نشده است (خطا یا E) تبیین شود. هرچه همبستگی بین عامل اصلی و متغیر قوی‌تر باشد اثر عامل پنهان یا خطا کمتر خواهد بود.

باشد. در مجموع تعداد ۲۱۰ عکس غیر تکراری از نمونه‌ها برداشته شد. سپس تصاویر تهیه شده برای انجام عملیات پردازش تصویر و ایجاد الگوریتم، در جعبه‌ابزار پردازش تصویر نرم‌افزار MATLAB (Mathworks, R2013a) بررسی شدند.

جدول ۱- درصد‌های وزنی مختلف خرده برنج در نمونه‌ها

نمونه	برنج خرده (درصد)	نمونه	برنج خرده (درصد)
۱	۰	۱۲	۵۵
۲	۵	۱۳	۶۰
۳	۱۰	۱۴	۶۵
۴	۱۵	۱۵	۷۰
۵	۲۰	۱۶	۷۵
۶	۲۵	۱۷	۸۰
۷	۳۰	۱۸	۸۵
۸	۳۵	۱۹	۹۰
۹	۴۰	۲۰	۹۵
۱۰	۴۵	۲۱	۱۰۰
۱۱	۵۰		

بر روی تصاویر گرفته شده پیش‌پردازش صورت گرفت. بدین‌صورت که تمام تصاویر برش داده (کراپ) شدند و به اندازه  $۸۴۵ \times ۸۳۳$  پیکسل درآمدند تا تصویر پس زمینه از تصاویر از بین برود. مستطیل انتخاب شده به اندازه‌ای بود که در همه تصاویر در میان توده گسترده شده برنج قرار می‌گرفت و شامل اطراف نبود. تصاویر تغییر اندازه داده شده ابتدا از فضای رنگی RGB به فضای خاکستری تبدیل شدند (شکل ۲). با این کار مقداری از نوفه تصاویر حذف شد. با استفاده از برنامه MATLAB و کدهای استخراج ویژگی‌های ماتریس هم‌رخداد، ماتریس هم‌رخداد سطح خاکستری<sup>۱</sup> (GLCM) تشکیل شد. از آنجا که دانه‌های برنج به طور تصادفی در هر جهتی می‌توانند قرار بگیرند، ویژگی‌های استخراج شده نباید تابع جهت خاصی باشند و لذا هر ویژگی در چهار جهت مختلف (صفر درجه، ۴۵، ۹۰ و ۱۳۵) برای تصاویر حاصل تشکیل و میانگین آن به عنوان ویژگی بافتی مورد نظر استخراج شد (Soh & Tsatsoulis, 1999; Clausi, 2002; Gonzalez & Woods, 2008; Mousavirad & Akhlaghian Tab, 2013).

گذاشته شد. از شبکه عصبی برای تعیین درصد خرد نمونه برنج با استفاده از ویژگی‌های بافتی و مقایسه با درصد‌های اندازه‌گیری شده از قبل استفاده شد. برای اعمال نتایج به‌دست‌آمده بر روی تصاویر، بهترین شبکه عصبی ذخیره شد و مورد استفاده قرار گرفت. در این پژوهش از شبکه‌های عصبی مصنوعی پرسپترون پیش‌خور با روش تعلیم پس‌انتشار خطا، روش یادگیری لوبنبرگ-مارکوارت و تابع تانزانت سیگموئید به عنوان تابع فعالیت استفاده شد (Mousavirad et al., 2012; Pazoki et al., 2014; Pourdarbani et al., 2019).

معماری‌های مختلفی از شبکه عصبی با تغییر تعداد نرون‌ها در لایه‌های پنهان ایجاد شدند. در کلیه شبکه‌ها از نرخ تعلیم ۰/۵ استفاده گردید. برای جلوگیری از بیش‌آموزی، داده‌ها (۷۰ درصد داده باقی مانده) به‌طور تصادفی به سه قسمت تقسیم شدند به طوری که ۶۰ درصد داده برای آموزش، ۱۵ درصد داده‌ها برای اعتبار سنجی و ۲۵ درصد داده برای آزمون شبکه استفاده شد (Pourdarbani et al., 2019). در حین آموزش شبکه زمانی که در ۶ چرخه آموزش متوالی خطای بین داده‌های آموزش و اعتبار سنجی افزایش یافت، فرآیند آموزش قطع گردید. برای انتخاب بهترین شبکه دو معیار میانگین مربعات خطا (MSE) و ضریب تبیین ( $R^2$ ) بین داده‌های خروجی شبکه و داده‌های هدف مورد استفاده در آموزش شبکه از معادلات (۲) و (۳) محاسبه شد.

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_{ANNi} - Y_{meai})^2 \quad (2)$$

$$R^2 = \left[ 1 - \frac{\sum_{i=1}^N (Y_{meai} - Y_{ANNi})^2}{\sum_{i=1}^N (Y_{ANNi})^2} \right] \times 100 \quad (3)$$


N: تعداد نمونه‌ها

$Y_{ANNi}$ : خروجی شبکه برای نمونه شماره  $i$  ام

$Y_{meai}$ : مقدار اندازه‌گیری شده واقعی برای نمونه شماره  $i$  ام.

شبکه با کمترین مقدار میانگین مجذور مربعات خطا و بیشترین مقدار ضریب تبیین در مرحله آموزش به عنوان کاراترین شبکه انتخاب شد. در نهایت قدر مطلق میانگین خطای نسبی تخمین مدل برای ۳۰ درصد داده‌های واسنجی با معادله (۴) محاسبه شد.

$$MAE = \frac{1}{N} \left( \sum \frac{|Y_{meai} - Y_{ANNi}|}{Y_{meai}} \right) \times 100 \quad (4)$$



شکل ۳- ارتباط بین متغیرها، عامل‌های اصلی و پنهان

چون به صورت معمول تعداد عامل‌ها در ابتدا برابر تعداد متغیرها (ویژگی‌ها) است، با استفاده از معیار نمودار اسکری<sup>۱</sup> تعداد عامل‌ها کاهش داده شد. این پردازش برای کاهش حجم ورودی‌های مدل و در نهایت افزایش سرعت پردازش و ساده شدن توپولوژی مدل شبکه عصبی ضرورت دارد. معمولاً عامل‌هایی با مقادیر ویژه بالاتر از ۱ در این نمودار به عنوان عامل نهایی انتخاب می‌شوند (DeCoster, 1998; Zare Chahoki, 2014). این محاسبات با نرم‌افزار SPSS 24 انجام شد. برای اینکه اثر مستقل عامل‌های نهایی (از یکدیگر) بر متغیرها (ویژگی‌ها) در مدل سازی لحاظ شود، چرخش متعامد در عامل‌ها انجام شد. برای این چرخش روش واریماکس انجام شد (DeCoster, 1998). همان‌طور که از نام این چرخش مشخص است این چرخش بدنبال حداکثر کردن واریانس عامل‌ها بر متغیرهای مرتبط با آن است. در چنین حالتی واریانس یک عامل برای تعدادی از متغیرها (ویژگی‌ها)، حداکثر و برای عامل دیگر حداقل خواهد شد. در نتیجه این عمل، واریانس برای عامل‌ها نسبت به حالت قبل از چرخش یکنواخت‌تر خواهد شد. به عبارتی اثر تعدادی از متغیرها در یک عامل و اثر متغیرهای دیگر در عامل دیگر به حداکثر رسیده است و این موضوع برای عامل‌های انتخاب شده دیگر هم به همین نحو خواهد بود. عمل چرخش، دسته‌بندی متغیرها و تفسیر آنها را ساده‌تر می‌کند. عامل‌های انتخاب شده نهایی به عنوان ورودی و درصد خرد برنج به عنوان خروجی به شبکه عصبی وارد شدند.

#### مدل شبکه عصبی مصنوعی

ابتدا ۳۰ درصد داده‌ها (سه داده از هر یک از ۲۱ گروه) برای واسنجی مدل به صورت تصادفی انتخاب و کنار

## نتایج و بحث

حداقل مقدار محاسبه شده ضریب KMO برابر  $0/7637$  بدست آمد و این مقدار نشان داد که همه ویژگی‌های محاسبه شده قابلیت ورود به تحلیل عاملی را دارند. بنابر این تحلیل عاملی با در نظر گرفتن همه ویژگی‌های مستخرج شده از تصاویر صورت گرفت و همبستگی اشتراکی عامل‌ها برای هر ویژگی محاسبه شد (جدول ۲). برای مثال در ستون استخراجی از متغیر «وابستگی ذاتی (خودبه‌خود)»<sup>۱</sup> ملاحظه می‌شود که  $99/6$  درصد از واریانس امتیازات این متغیر، توسط عامل‌ها تبیین می‌شود. ستون اولیه گویای تمامی اشتراک‌های قبل از استخراج است که به صورت پیش فرض یک در نظر گرفته می‌شود. یعنی فرض آن است که این متغیر در شکل‌گیری عامل  $100$  درصد تاثیر دارد؛ پس تمامی آن‌ها برابر یک هستند. همان‌گونه که مشاهده می‌شود پس از تعیین میزان همبستگی، مقدار اشتراک واقعی در ستون دوم (جدول ۲) محاسبه شد. تمامی میزان اشتراک‌ها بالاتر از  $0/5$  است و تنها عامل «بیشینه احتمال» با مقدار  $0/679$ ، کمترین میزان اشتراک را نسبت به سایر عامل‌ها دارد، که بیانگر توانایی عامل‌های تعیین شده در تبیین واریانس متغیرهای مورد مطالعه است. در ستون اول جدول ۳ مقادیر ویژه اولیه برای هر یک از عامل‌ها (مجموع همبستگی عامل با ویژگی‌ها یا متغیر) برآورد شده است. ستون دوم سهم واریانس آن عامل از واریانس کل است که از تقسیم مقدار ویژه آن عامل بر تعداد عامل‌ها به دست می‌آید. قسمت دوم مربوط به مقادیر ویژه عوامل استخراجی بدون چرخش است و عامل‌هایی ارائه شده که مقادیر ویژه آن‌ها بزرگ‌تر از ۱ است (DeCoster, 1998). قسمت سوم این جدول مجموعه مقادیر عامل‌های استخراج شده بعد از چرخش را نشان می‌دهد. با توجه به واریانس تجمعی این قسمت سه عامل قابلیت تبیین واریانس‌ها را دارند. عامل‌های ۱، ۲ و ۳ دارای مقادیر ویژه بزرگ‌تر از ۱ هستند و در تحلیل باقی می‌مانند. همان‌طور که در ستون واریانس تجمعی نسبی دیده می‌شود این سه عامل می‌توانند در  $95/55$  درصد واریانس متغیرها را توضیح دهند. در چرخش عامل‌های باقی‌مانده، نسبتی از کل تغییرات که توسط این سه عامل توضیح داده می‌شود ثابت است ولی برخلاف روش بدون چرخش که در آن عامل اول درصد

بیشتری از تغییرات ( $75/0$  درصد) را تعیین می‌کند، هر یک از عامل‌ها نسبت یکسان‌تری از تغییرات را توضیح می‌دهند. عامل‌های اول، دوم و سوم بدست آمده با روش چرخش واریانس، به ترتیب  $48/7$ ،  $26/49$  و  $20/36$  درصد و در مجموع  $95/55$  درصد از واریانس را دربردارند.

جدول ۲- میزان همبستگی اشتراکی عامل‌ها برای هر ویژگی وارد شده در تحلیل عاملی

ویژگی (متغیر)	همبستگی
Autocorrelation	$0/996$
Contrast	$0/973$
Correlation I	$0/987$
Correlation II	$0/987$
Cluster Prominence	$0/830$
Cluster Shade	$0/851$
Dissimilarity	$0/999$
Energy	$0/909$
Entropy	$0/984$
Homogeneity I	$0/979$
Homogeneity II	$0/986$
Maximum probability	$0/679$
Sum of square	$0/996$
Sum average	$0/998$
Sum variance	$0/995$
Sum entropy	$0/940$
Difference variance	$0/973$
Difference entropy	$0/994$
Information of measure correlation1	$0/990$
Information of measure correlation2	$0/978$
Inverse difference	$0/979$
Inverse difference normalized	$0/999$
Inverse difference moment normalized	$0/974$

شکل ۴ تغییرات مقادیر ویژه را در ارتباط با عامل‌ها نشان می‌دهد. این نمودار برای تعیین تعداد بهینه مؤلفه‌ها به کار می‌رود. برای مشخص کردن تعداد عامل‌ها از روی این نمودار کافی است خط  $y=1$  رسم شود. عامل‌هایی که بالای این خط قرار داشتند به عنوان عامل‌های اصلی مورد استفاده قرار گرفتند (Zare Chahoki, 2014).

با توجه به این نمودار مشاهده می‌شود که از عامل سوم به بعد تغییرات مقدار ویژه کاهش یافت، بنابراین سه عامل نخست به عنوان عوامل مهم که بیشترین نقش را در تبیین واریانس داده‌ها دارند استخراج مورد استفاده قرار گرفت.

از آنجا که حجم اطلاعات اولیه برای محاسبه مؤلفه‌ها یا عامل‌های اصلی و در نهایت سرعت عملکرد الگوریتم در

قرار گرفت (جدول ۴). در این جدول هر متغیر (ویژگی مستخرج از تصویر) در عاملی قرار داده شد که با آن عامل همبستگی بالای معنادار داشته باشد.

یک سامانه برخط بسیار مهم است، با توجه به بردارهای ویژه و چرخش ۹۰ درجه‌ای واریماکس، تأثیرگذاری ویژگی‌های استخراج شده از تصویر بر عامل‌ها مورد بررسی

جدول ۳- مجموع مقادیر ویژه و درصد واریانس عامل‌های مختلف

عامل‌ها	مقدار ویژه اولیه			عامل چرخش داده نشده			عامل چرخش داده شده		
	مجموع	واریانس (درصد)	واریانس تجمع (درصد)	مجموع	واریانس (درصد)	واریانس تجمع (درصد)	مجموع	واریانس (درصد)	واریانس تجمع (درصد)
۱	۱۷/۲۴	۷۴/۹۷	۷۴/۹۷	۱۷/۲۴	۷۴/۹۷	۷۴/۹۷	۱۱/۲۰	۴۸/۷۰	۴۸/۷۰
۲	۳/۱۰	۱۳/۴۶	۱۳/۴۶	۳/۱۰	۱۳/۴۶	۱۳/۴۶	۶/۱۰	۲۶/۴۹	۲۶/۴۹
۳	۱/۶۴	۷/۱۲	۷/۱۲	۱/۶۴	۷/۱۲	۷/۱۲	۴/۶۸	۲۰/۳۶	۲۰/۳۶
۴	۰/۷۲	۳/۱۴	۳/۱۴	۰/۷۲	۳/۱۴	۳/۱۴	۰/۷۲	۰/۷۲	۰/۷۲
۵	۰/۱۷	۰/۷۳	۰/۷۳	۰/۱۷	۰/۷۳	۰/۷۳	۰/۱۷	۰/۱۷	۰/۱۷
۶	۰/۱۰	۰/۴۲	۰/۴۲	۰/۱۰	۰/۴۲	۰/۴۲	۰/۱۰	۰/۱۰	۰/۱۰
۷	۰/۰۲	۰/۰۷	۰/۰۷	۰/۰۲	۰/۰۷	۰/۰۷	۰/۰۲	۰/۰۲	۰/۰۲
۸	۰/۰۱	۰/۰۶	۰/۰۶	۰/۰۱	۰/۰۶	۰/۰۶	۰/۰۱	۰/۰۱	۰/۰۱
۹	۰/۰۰	۰/۰۱	۰/۰۱	۰/۰۰	۰/۰۱	۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۰
۱۰	۰/۰۰	۰/۰۱	۰/۰۱	۰/۰۰	۰/۰۱	۰/۰۱	۰/۰۰	۰/۰۰	۰/۰۰

جدول ۴- مقادیر عامل‌های چرخشی (دوران یافته) برای ویژگی‌های یافت تصویر (متغیرها)


ویژگی‌های یافت تصویر	عامل		
	۱	۲	۳
Info. measure of correlation2	۰/۹۷۵	-	-
Correlation I	۰/۹۷۲	-	-
Correlation II	۰/۹۷۲	-	-
Info. measure of correlation1	-۰/۹۲۲	-	-
Dissimilarity	-۰/۸۴۰	-	-
Inv. difference normalized	۰/۸۴۰	-	-
Homogeneity II	۰/۸۳۳	-	-
Homogeneity I	۰/۸۲۹	-	-
Inverse difference	۰/۸۲۹	-	-
Contrast	-۰/۸۲۵	-	-
Cluster Shade	-۰/۸۵۶	-	-
Cluster Prominence	۰/۸۴۶	-	-
Sum entropy	۰/۸۲۸	-	-
Maximum probability	-۰/۷۰۹	-	-
Sum variance	۰/۹۵۷	-	-
Sum average	۰/۹۵۵	-	-
Autocorrelation	۰/۹۵۰	-	-
Sum of squares	۰/۹۴۹	-	-
Difference entropy	-۰/۸۳۵	۰/۵۱۰	-
Difference variance	-۰/۸۲۵	۰/۵۱۲	-
Inv. moment diff. normalized	۰/۸۲۶	-۰/۵۱۲	-
Entropy	-۰/۶۸۲	۰/۶۸۱	-
Energy	۰/۵۴۳	-۰/۷۰۳	-

است در عامل اول قرار گرفتند. متغیرهایی که قدرمطلق ضرایب عاملی آن‌ها در عامل دوم بزرگ‌تر از ۰/۹ و در عامل اول و سوم کمتر از ۰/۵ است در عامل دوم، و بر همین منوال متغیرهایی که قدر مطلق ضرایب عاملی آن‌ها در عامل سوم بزرگ‌تر از ۰/۹ و در عامل اول و دوم کمتر از ۰/۵ است در عامل سوم قرار گرفتند.

برای تشخیص راحت‌تر رابطه بین متغیرها و عامل‌ها از درج ضرایب کمتر از ۰/۵ خودداری شده است. مطابق این خروجی، عامل اصلی اول با تعداد ۱۰ ویژگی مستخرج از تصاویر بیشترین تأثیر را در تخمین درصد خرده برنج داشته است. چهار ویژگی مستخرج شده Sum variance، Sum average و Autocorrelation و Sum of square تأثیرگذار در تشکیل عامل سوم با بالاترین ضرایب تأثیر، نسبت به ویژگی‌های مؤثر در عامل دوم توانست درصد خرده برنج را بهتر تخمین بزند. جدول ۴ همچنین نشان داد که چهار ویژگی مرتبط با عامل اول و چهار ویژگی مرتبط با عامل دوم با ضرایب بالاتر از ۰/۹۰ بیشترین تأثیر را در تخمین درصد خرده برنج داشتند.

پنج ویژگی به طور همزمان در تشکیل دو عامل اول و دوم تأثیرگذار بوده است و طبیعی است لحاظ نشدن آن‌ها تأثیر قابل توجهی در قدرت تشخیص و تخمین خرده برنج خواهد گذاشت. بنابراین این ویژگی‌ها در رتبه دوم در تخمین درصد خرده برنج مؤثر بوده‌اند.


متغیرهایی که قدر مطلق ضرایب عاملی آن‌ها در عامل اول بزرگ‌تر از ۰/۹ و در عامل‌های دوم و سوم کمتر از ۰/۵



شکل ۳- همبستگی درصد خرده برنج واقعی و مدل شده با شبکه عصبی ۱-۸-۶-۳ (الف: اعتبارسنجی، ب: آموزش، د: آزمون، ج: همه داده‌ها)

(Aghayeghazvini *et al.* (2009) استفاده از خصوصیات فیزیکی شامل اندازه و سطح مقطع دانه‌های برنج و پردازش تصویر موفق به تعیین خرده برنج شدند. خطای کلی تخمین این روش گزارش نشد، اما نتایج حاکی از آن بود که به طور سیستماتیک (ثابت) مدل خطای حدود ۲/۷ درصد در تخمین درصد برنج خرد شده داشت. (Mousavirad *et al.* (2012) برای طبقه‌بندی دانه برنج از شبکه‌های عصبی پسانتشار استفاده کردند. آنان درستی ۹۶/۶۷ درصد را برای دسته‌بندی گزارش نمودند. همچنین (Pazoki *et al.* (2014) با ۲۴ ویژگی رنگی، ۱۱ ویژگی مورفولوژیکی و ۴ عامل شکل از تصاویر رنگی دانه برنج توسط شبکه‌های پرسپترون به ضریب همبستگی ۹۹/۴۶ درصد (ضریب تبیین ۰/۹۸۹۲) موفق به جداسازی پنج رقم برنج ایرانی شدند که با نتایج پژوهش حاضر مطابقت دارد.

این در حالی است که سوماریانتی و همکاران با استفاده از شش ویژگی رنگی، چهار ویژگی مورفولوژی و دو ویژگی بافت تصویر ارقام مختلف برنج توانستند شناسایی برخی ارقام را با ضریب تبیین ۰/۷۰ انجام دهند (Sumaryanti *et al.*, 2015). همان‌طور که گزارش شده است تعداد، نوع، پیش پردازش داده‌ها و روش مدل‌سازی در دقت مدل‌های



شکل ۴- نمودار اسکری‌گراف برای تعیین تعداد عامل‌ها

### نتایج شبکه عصبی مصنوعی

اطلاعات ورودی و خروجی پیش گفته به شبکه پرسپترون چند لایه وارد شد. توپولوژی‌های مختلف مورد بررسی قرار گرفت. در نهایت در بین کلیه شبکه‌ها و دفعات تعلیم، شبکه‌ای با کمترین میزان خطای تخمین و بیشترین قدرت پیشگویی انتخاب شد و در شبیه‌سازی داده‌های آزمایشی مورد استفاده قرار گرفت. با توجه به مقادیر خطای ارزیابی شبکه با توپولوژی سه عامل اصلی ورودی، یک خروجی و دو لایه با تعداد شش نرون در لایه اول و هشت نرون در لایه دوم (۱-۸-۶-۳) با تعداد چرخه ۲۹ در همه سطوح خاکستری در بین کل نمونه‌ها، کمترین مقدار خطای آموزشی را ایجاد کرد (جدول ۵). این شبکه دارای ضریب تبیین  $(R^2) 0.9875$  بود (شکل ۳).

ترکیب روش تحلیل عددی و شبکه عصبی میانگین خطای نسبی کل تشخیص درصد خرده برنج را ۱/۵ درصد در پی داشت. (Mallah (2013) خطای تشخیص خرده برنج را بر اساس وارپته و یا فرآیند انجام شده بر روی شلتوک بین ۱/۲ تا ۲/۵ درصد گزارش کرد. بر اساس این مطالعه با در نظر گرفتن طول دانه درصد خطای تخمین خرده برنج برای ۱۰ و ۲۰ درصد اختلاط به ترتیب ۱/۳۴ و ۱/۷۹ درصد، و با در نظر گرفتن شکل دانه به ترتیب ۱/۲ و ۲/۵ درصد گزارش شد.

جدول ۵- نتایج مربوط به شبکه پرسپترون برای تعیین درصد خرده برنج در نمونه

توپولوژی	خطای ارزیابی	چرخه آموزش
۱-۱۰-۱۰-۳	۰/۰۰۰۴	۹
۱-۸-۸-۳	۰/۰۰۰۴	۱۶
۱-۱۰-۸-۳	۰/۰۰۰۵	۷
۱-۸-۶-۳	۰/۰۰۰۲	۲۹



3. Bato, P. M., Nagata, M., Cao, Q., Shrestha, B. P., & Nakashima, R. (1999). Strawberry Sorting using Machine Vision. *ASAE*, Paper No. 9931162-993162.9.
  4. Chen, X. J., Wu, D., He, Y., & Liu, S. (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.
  5. Clausi, D. A. (2002). An analysis of co-occurrence texture statistics as a function of grey level quantization. *Canadian Journal of Remote Sensing*, 28(1): 45-62.
  6. Courtois, F., Abud, M., & Bonazzi, C. (2001). Modeling and control of a mixed-flow rice dryer with emphasis on breakage quality. *Journal of Food Engineering*, 49: 303-309.
  7. Courtois, F., Faessel, M., & Bonazzi, C. (2010). Assessing breakage and cracks of parboiled rice kernels by image analysis techniques. *Food Control*, 21(4): 567-572.
  8. Dalen G. V. (2004). Determination of the size distribution and percentage of broken kernels of rice using flatbed scanning and image analysis. *Food Research International*, 37(1): 51-58.
  9. DeCoster, J. (1998). Overview of Factor Analysis. Retrieved <Aug., 10, 2020> from <http://www.stat-help.com/notes.html>.
  10. Faraji, Z., Ramezani, F., & Motameni, H. (2016). To present method for rice variety identification with fuzzy-imperialist competitive algorithm. *Journal of Advances in Computer Research*, 7(2): 41-52.
  11. Gonzalez, R. C., & Woods, R. E. (2008). *Digital Image Processing*. New Jersey: Pearson Prentice Hall.
  12. Gudipalli, A., Prabha, A. N., Reddy, P. Ch. (2016). A review on analysis and grading of rice using image processing. *ARPJ Journal of Engineering and Applied Science*, 11(23): 13550-13555.
  13. Liu, Z., Cheng, F., Ying, Y., & Rao, X. (2005). Identification of rice seed varieties using neural network. *Journal of Zhejiang University of Science*, 6(11): 1095-1100.
  14. Majumdar, S., & Jayas, D. S. (2000). Classification of cereal grains using machine vision: III. Texture models. *Transactions of the ASAE*, 43(6): 1681-1687.
  15. Mallah, C. D. (2013). *On-line measurement of broken rice percentage from image analysis of length and shape*. Ph.D. dissertation. Faculty of Science, Engineering and Computing, School of Computing and Information System. Kingstone University, London.
- طبقه‌بندی و جداسازی تأثیر گذار بوده است به نحوی که میانگین دقت ۴۶ درصد تا ۹۸/۸ درصد برای پژوهش‌های پیشین گزارش شد ( Veena & Latharani, 2014; ) (Gudipalli et al., 2016).
- در گزارش Pourdarbani et al. (2019) نیز تفاوت روش پیش پردازش کاهش تعداد ویژگی‌های ورودی حاکی از تغییر در دقت دسته‌بندی نخودهای با ارقام مختلف بود و این نتیجه نیز حاصل شد که لزوماً هر روش کاهش ویژگی افزایش دقت خروجی مدل را به دنبال ندارد. مقدار ۱/۹ درصد خطا در دسته‌بندی نیز در این روش داده کاوی گزارش شد. در پژوهش حاضر تحلیل عاملی ورودی شبکه عصبی را برای مدل‌سازی کاهش داد، در حالی که در اکثر مطالعات پیشین کل ویژگی‌های استخراج شده از تصاویر برای مدل‌سازی مورد استفاده قرار گرفت.
- ### نتیجه‌گیری
- اعمال روش تحلیل عاملی به منظور کاهش داده‌ای ورودی شبکه عصبی در عین حفظ اثر ویژگی‌های مستخرج شده از تصاویر نمونه‌هایی از مخلوط برنج سالم و خرد شده ضمن کوچک‌سازی توپولوژی شبکه، نشان داد که این شبکه عصبی با توپولوژی ۱-۸-۶-۳ با کمترین خطای تخمین ۰/۰۰۰۲ آموزش و قدرت تبیین ۰/۹۵۷۵ با سه عامل اصلی توانایی بالایی در تعیین درصد (وزنی) خرد برنج با خطای حدود ۱/۵ درصد (وزنی) دارد. با توجه به نتایج به‌دست‌آمده می‌توان از روش پردازش تصویر برای تعیین درصد برنج خرد و در نتیجه درجه‌بندی برنج به عنوان روش جایگزین روش‌های دستی استفاده نمود.
- ### منابع
1. Aghayeghazvini, H., Afzal, A., Heidarisoltanabadi, M., Malek, S., & Mollabashi, L. (2009). Determining percentage of broken rice by using image analysis. in *IFIP International Federation for Information Processing (294), Computer and Computing Technologies in Agriculture II(2)*, eds. D. Li, Z. Chunjiang, (Boston: Springer), 1019-1027.
  2. Aulakh, J. S., & Banga, V. (2012). *Percentage purity of rice sample by image processing*. In International conference on Trends in Electrical, Electronics and Power Engineering, Singapore (pp. 15-16).

and neural networks. Part I. Single kernel texture. *Journal of Cereal Science*, 54(1): 60-68.

27. Zare Chahoki, M. A. 2014. Data analysis in natural resources research using SPSS software. Academic Jahad. 312P. (In Persian).
- Zhang, X., Cui, J., Wang, W., & Lin, Ch. (2017). A Study for Texture Feature Extraction of High-Resolution Satellite Images Based on a Direction Measure and Gray Level Co-Occurrence Matrix Fusion Algorithm. *Sensors*, 17: 1474; doi: 10.3390/s17071474.
16. Mousavirad, S. J., & Akhlaghian Tab, F. (2013). Design of an expert system to identify the authenticity of rice cultivars using a combination of textural features of batch rice images. *Journal of Machine Vision and Image Processing*, 1(1): 11-18.
17. Mousavirad, S. J., Akhlaghian Tab, F., & Mollazade, K. (2012). Classification of rice varieties using optimal color and texture features and BP neural networks. *The 7<sup>th</sup> Iranian Conferences on Machine Vision and Image Processing*. Tehran, Iran.
18. Nassiri, S. M., Abdirad, M., Zare, D., Nematollahi, M. A., & Safar Razavizadeh, N. (2019). Microwave radiations replacement instead of steam to paddy parboiling. *Iran Journal of Biosystems Engineering*, 50(2): 463- 474. (In Persian).
19. Pabamalie L., & Premaratne, H. (2011). An intelligent rice quality classifier. *International Journal of Internet Technology and Secured Transactions*, 3: 386-406.
20. Pazoki, A. R., Farokhi, F., & Pazoki, Z. (2014). Classification of Rice Grain Varieties Using Two Artificial Neural Networks (MLP and Neuro-Fuzzy). *Journal of Animal and Plant Sciences*, 24: 336-343.
21. Pourdarbani, R., Sabzi, S., Garcia-Amicis, V., Garcia-Mateos G., Molina-Martinez J. M., & Ruiz-Canales, A. (2019). Automatic classification of chickpea varieties using computer vision techniques. *Agronomy*, 9(11): 672.  
<https://doi.org/10.3390/agronomy9110672>
22. Pourreza, A., Pourreza, H. R., Abbaspour-Fard, M. H., & Sadrnia, H. (2012). Identification of nine Iranian wheat seed varieties by textural analysis with image processing. *Computers and Electronics in Agriculture*, 83(2): 102-108.
23. Soh, L. K., & Tsatsoulis, C. (1999). Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices. Institute of Electrical and Electronics Engineers. *Transactions on Geoscience and Remote Sensing*, 37(2): 780-795.
24. Sumaryanti, L., Musdholifah, A., & Hartati, S. (2015). Digital image based identification of rice variety using image processing and neural network. *Telkomnika Indonesian Journal of Electrical Engineering*, 16(1): 182-190.
25. Veena, H., & Latharani, T. R. (2014). An efficient method for classification of rice grains using Morphological process. *International Journal of Innovative Research in Advanced Engineering*, 1(1): 218-221.
26. Zapotoczny, P. (2011). Discrimination of wheat grain varieties using image analysis