

تلفیق ماشین بردار پشتیبان با ویژگی‌های ماتریس GLRM به منظور طبقه‌بندی سه رقم گندم

مصطفی خجسته نژاد^{۱*}، مظفر روستائی^۲

۱. گروه مهندسی مکانیک، دانشکده فنی و مهندسی، دانشگاه بناب، بناب، ۵۵۵۱۷۶۱۱۶۷، ایران (khojasteh@ubonab.ac.ir)
۲. موسسه تحقیقات کشاورزی دیم کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، مراغه - ایران (roustaii@yahoo.com)

چکیده

گندم یکی از محصولات مهم و استراتژیک کشاورزی است که نقش مهم و بسزائی را در تامین زنجیره غذایی انسان‌ها بازی می‌کند. در این میان، براساس شرایط اقلیمی و آب و هوایی، ارقام خاصی برای کشت در هر منطقه پیشنهاد می‌شود تا ضمن بالا بردن کیفیت محصول نهایی، راندمان مزرعه‌ای نیز افزایش پیدا کند. در روش‌های سنتی، تشخیص ارقام مختلف گندم توسط کارشناسان خبره انجام می‌پذیرد که به دلیل خستگی، سرعت پایین و تصمیم‌گیری مبتنی بر نظرات شخصی، خالی از اشکال نیست. برای رفع این مشکل، امروزه از روش‌های غیرمخرب از جمله بینایی ماشین استفاده می‌گردد. در این تحقیق نیز با استفاده از روش بینایی ماشین، اقدام به استخراج ویژگی‌های بافت توسط الگوریتم GLRM در چهار جهت صفر، ۴۵، ۹۰ و ۱۳۵ درجه شده و با تشکیل پایگاه داده مورد نظر توسط طبقه بندی کننده ماشین بردار پشتیبان (SVM)، سه رقم مختلف هما، صدرا و سرداری طبقه‌بندی گردیده است. نتایج تحقیق نشان داد که مدل SVM با تابع مرکزی خطی یا چند جمله‌ای می‌تواند با دقت بالای ۹۷٪ هر سه رقم گندم مورد استفاده را شناسایی و طبقه‌بندی نماید. حساسیت، ویژگی و نرخ کلاس‌بندی صحیح هر سه رقم نیز بالای ۹۷٪ بدست آمد که نشان دهنده دقت بالای مدل SVM بر روی پایگاه داده تشکیل یافته از ویژگی‌های GLRM می‌باشد. نتایج بیانگر قابلیت بسیار بالای روش بینایی ماشین در طبقه‌بندی و شناسایی ارقام مختلف گندم است و می‌تواند به عنوان روشی مورد اعتماد استفاده گردد.

کلمات کلیدی:

پردازش تصویر، بینایی ماشین، بافت، ویژگی، گندم

*نویسنده مسئول: مصطفی خجسته نژاد، khojasteh@ubonab.ac.ir

تلفیق ماشین بردار پشتیبان با ویژگی‌های ماتریس GLRM به منظور طبقه‌بندی سه رقم گندم

مقدمه


گندم بعنوان یکی از محصولات مهم و استراتژیک کشاورزی است که جهت تغذیه میلیاردها انسان در کره خاکی تحت عنوان مواد غذایی مختلف مورد استفاده قرار می‌گیرد. استفاده از گندم به دلیل دانه‌های سرشار از نشاسته، پروتئین، لیپید، مواد معدنی و مغذی می‌باشد. با توجه به اینکه براساس شرایط آب، هوا و خاک هر منطقه، ارقام مختلفی کشت می‌شود، بر این اساس ارقام مختلف برای هر منطقه آب و هوایی ارائه گردیده است تا ضمن سازگاری با شرایط، محصولی پر بازده و غنی از مواد مغذی تولید گردد. در منطقه شمال غرب ایران (آذربایجان) نیز رقم‌های مختلف کشت وجود دارد که از بهترین و پر محصول‌ترین آن می‌توان به ارقام سرداری، صدرا و هما اشاره نمود. از آنجائیکه دقت در انتخاب بذر کاشته شده از اهمیت بسیار بالایی برخوردار است و عدم دقت در انتخاب رقم مورد نظرباعث کاهش کیفیت محصول تولیدی و همچنین رلندمان مزرعه‌ای خواهد شد، معمولاً از افراد خبره جهت شناسایی ارقام استفاده می‌گردد. البته به دلیل شباهت‌های ظاهری بسیاری از ارقام، در برخی موارد افراد خبره نیز دچار شک و تردید می‌شوند. و از طرف دیگر به دلیل سرعت پایین، خستگی و تصمیم‌گیری مبتنی بر شخص و همینطور دقت پایین، روش مرسوم دارای ایرادات بزرگی است. بدین منظور در سال‌های اخیر در کنار رشد و پیشرفت علوم مختلف از جمله علوم رایانه‌ای، روش‌های خودکار غیرتجانسی در زمینه‌های مختلف ارائه گردیده‌اند که با بالا بردن دقت شناسایی، کیفیت محصول را نیز بهبود بخشیده‌اند. استفاده از این روش‌ها در زمینه‌های مختلف نظامی، شهری، صنایع و کشاورزی به صورت مکرر اتفاق افتاده است که در بخش کشاورزی و مواد غذایی با استفاده از برخی خصوصیات ظاهری یا داخلی محصول، اقدام به طبقه‌بندی و تشخیص می‌نمایند. روش بینایی ماشین به عنوان یکی از روش‌های غیرتجانسی در سال‌های اخیر مورد استفاده قرار گرفته است که با الهام‌گیری از چشم انسان و پدیده نور اقدام به استخراج ویژگی‌های مختلفی می‌نماید و براساس آن ویژگی‌ها، کارهای مختلفی از جمله تشخیص میزان رسیدگی محصول [5]، تشخیص ناحیه بیماری محصول، تشخیص عیب و اندازه عیب محصول [۷] و درجه‌بندی و کلاس‌بندی انواع محصولات کشاورزی [۶] و مواد غذایی انجام پذیرفته است. در رابطه با محصول گندم نیز استفاده‌های مکرری از این روش شده است [۳ و ۸] در برخی از تحقیقات به منظور تشخیص بذرهای جوانه زده، آفت زده، شکسته و ناسالم از روش بینایی ماشین و پردازش تصویر استفاده گردیده است [۱۲]. در برخی موارد نیز جهت طبقه‌بندی رقم‌های مختلف با استفاده از ویژگی‌های تصویر، از این روش استفاده کرده‌اند [۳ و ۱۱]. در تحقیقی که بر روی گندم بذری نیز انجام پذیرفته است، با استخراج ویژگی‌های ماتریس هم-رخدادی در کنار ویژگی‌های شکل و رنگ اقدام به تشخیص دانه‌های گندم سالم و ناسالم گردیده است که بطور میانگین دقت بالای ۹۷/۴ درصد گزارش گردیده است [۱]. در تحقیق دیگری نیز عملکرد تافیق شبکه عصبی مصنوعی با ویژگی‌های ماتریس هم-رخدادی بر روی محصول برنج مورد بررسی قرار گرفته است [۲]. در تمامی تحقیقات انجام یافته، دقت روش بینایی ماشین قابل قبول بوده و آنرا به عنوان روشی مورد اعتماد معرفی کرده است. در این روش براساس نیاز و کاربرد، اقدام به استخراج خصوصیات مانده اندازه (مساحت سطح تصویر شده، طول و عرض، قطر، محیط) شکل، رنگ و بافت نمونه شده و براساس آنها طبقه‌بندی محصول انجام پذیرفته است. خصوصیات بافت تصویر در مورد محصولات دانه‌ای همچون گندم، برنج، کشمش و ... دارای اطلاعات بسیار مفیدی برای طبقه‌بندی و شناسایی ارقام مختلف هست. استخراج خصوصیات بافت توسط الگوریتم‌های مختلفی انجام می‌پذیرد که از پرکاربردترین آنها می‌توان به ماتریس طولی سطح خاکستری (Gray Level Run Length Matrix (GLRM)) اشاره نمود. با استفاده از

ویژگی‌های ماتریس GLRM اقدام به طبقه‌بندی محصولات دانه‌ای از جمله کشمش فله‌ای [۴] و برخی ارقام گندم [۱۱] شده است. با استخراج خصوصیات بافت و تشکیل پایگاه داده برای هر نمونه محصول، با روش‌های مختلف مدل‌سازی از جمله ماشین بردار پشتیبان (SVM) عملیات طبقه‌بندی بر روی محصولات مختلف انجام پذیرفته که نتایج نشان دهنده تعامل سازنده این روش مدل‌سازی با ویژگی‌های GLRM دارد. براساس توضیحات داده شده و بیان اهمیت موضوع، و همچنین قابلیت‌های روش بینایی ماشین، در این تحقیق اقدام به استخراج ویژگی‌های مختلفی از بافت سه رقم گندم ایرانی شده و دقت مدل طبقه‌بندی کننده ماشین بردار پشتیبان تحت چهار تابع مرکزی متفاوت براساس مقادیر ماتریس اغتشاش آنها مورد ارزیابی قرار گرفته است.

مواد و روش‌ها

سامانه بینایی ماشین

سامانه ماشین بینایی مورد استفاده در این تحقیق شامل جعبه تصویربرداری، دوربین و بخش نورپردازی می‌باشد. از جعبه تصویربرداری برای دریافت تصاویر نمونه‌های تهیه شده در شرایط یکسان و حذف نورهای زائد محیطی استفاده شد. در قسمت بالای جعبه، یک عدد دوربین (CMOS Logitech C920 HD pro Webcam) با وضوح 1080×1920 پیکسل و سرعت ۳۰ فریم بر ثانیه در مرکز قرار گرفته است. با توجه به اینکه شرایط نورپردازی باید به نحوی باشد که تا حد امکان از ایجاد سایه بر روی تصویر جلوگیری نماید و همین‌طور نور یکنواختی در تمام نواحی تصویر فراهم گردد از یک عدد پانل ال ای دی دایره ای ۱۸ وات در بالای جعبه استفاده گردید. فاصله دوربین و منبع نور از کف جعبه برابر ۵۰ سانتی‌متر بود و در تهیه تصویر تمام نمونه‌ها، شرایط نورپردازی، فاصله و تنظیمات دوربین در حالت یکسانی تنظیم گردید. از یک رایانه شخصی نیز جهت ذخیره و تجزیه و تحلیل تصاویر استفاده شد. شکل ۱ شماتیک سامانه ماشین بینایی مورد استفاده را نشان می‌دهد.



شکل ۱: شماتیک سامانه ماشین بینایی

تهیه نمونه

۳ رقم نمونه گندم بنام‌های هما، صدرا و سرداری از مرکز تحقیقات دیم شمال غرب کشور واقع در شهر مراغه تهیه گردید. ابتدا توسط یک کارشناس خبره، ناخالصی نمونه‌ها از مواد زائد و دیگر ارقام پاکسازی گردید. طریقه تصویربرداری از نمونه‌ها و تشکیل پایگاه داده بدین صورت بود که ابتدا از هر رقم به اندازه ۲۰۰ گرم در داخل ظرفی به ابعاد ۲۰*۲۰*۴ ریخته شده و بعد از مسطح نمودن سطح محصول با دست، در زیر دوربین تصویربرداری قرار می‌گرفت. با بستن درب جعبه تصویربرداری، اولین تصویر از نمونه تهیه شده و مجدداً با برهم‌زدن نمونه‌های داخل ظرف و مسطح نمودن سطح آن تصویر بعدی اخذ می‌شد. این کار برای هر رقم، ۵۰ بار تکرار شد و از ۳ رقم نمونه گندم، ۱۵۰ تصویر تهیه و بعنوان پایگاه اصلی داده جهت محاسبات بعدی در حافظه رایانه ذخیره گردید. شکل ۲ تصویر نمونه ارقام مورد استفاده را نشان می‌دهد. همانگونه که از تصاویر نیز مشخص است، تشخیص ارقام مختلف محصول توسط انسان، بغیر از افراد خبره غیر ممکن است که حتی در برخی موارد افراد خبره نیز دچار شک و تردید می‌شوند و بر این اساس استفاده از روش‌های خودکار هوشمند از جمله ماشین بینایی اجتناب‌ناپذیر است.



سرداری

صدرا

هما

شکل ۲: ارقام گندم مورد استفاده برای تصویربرداری

استخراج ویژگی

همانطور که در بخش مقدمه نیز بیان گردید، یکی از روش‌های بررسی کیفیت محصولات دانه‌ای همانند گندم، برنج و کشمش، بررسی بافت آنها می‌باشد. برای بررسی بافت تصاویر، الگوریتم‌های مختلفی موجود می‌باشد که یکی از پرکاربردترین آنها در بخش کشاورزی و مواد غذایی استفاده از ماتریس GLRM است این ماتریس برای هر سطح خاکستری، اندازه اجراهای همگن را استخراج نموده و پارامترهای آماری مرتبه بالاتر یک تصویر با تشکیل ماتریس GLRM آن محاسبه می‌شود. این ماتریس برای محاسبه ۱۱ ویژگی بافت که در جدول ۱ بیان شده‌اند، در چهار جهت همسایگی مختلف (صفر، ۴۵، ۹۰ و ۱۳۵ درجه) با انحراف ۱ مورد استفاده قرار می‌گیرد. عنصر (i, j) از ماتریس GLRM به تعداد اجراهای همگن پیکسل i در یک تصویر مطابقت دارد که $GLRM(i, j)$ نامیده می‌شود. ردیف‌های ماتریس نشان دهنده سطوح خاکستری است در حالی که ستون‌های ماتریس تعداد سطوح خاکستری مربوطه را نشان می‌دهد. جدول ۱، ۱۱ ویژگی آماری مورد استفاده و روابط آنها نشان داده شده است. با توجه به ویژگی‌های ماتریس،

برای هر تصویر ۴۴ ویژگی که شامل ۱۱ ویژگی بیان شده در جدول ۱ در چهار جهت مختلف می‌شد، استخراج گردیده و در پایگاه داده ذخیره گردید [۱۱].

طبقه‌بندی با ماشین بردار پشتیبان (SVM)

SVM یکی از روش‌های یادگیری بانظارت است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌شود. مبنای کاری دسته‌بندی کننده SVM، دسته‌بندی خطی داده‌ها است و در طبقه بندی خطی را انتخاب می‌کند که حاشیه اطمینان بیشتری داشته باشد. حل معادله و پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های مختلفی از جمله Linear, Polynomial, Radial Basis و Sigmoid که روش‌های شناخته شده‌ای در حل مسائل محدودیت‌دار هستند، صورت می‌گیرد. SVM از تکنیکی که kernel trick نامیده می‌شود، برای تبدیل داده‌ها استفاده می‌کند و سپس براساس این تبدیل، مرز بهینه بین خروجی‌های ممکن را پیدا می‌کند. به عبارت ساده تبدیلات بسیار پیچیده را انجام می‌دهد، سپس مشخص می‌کند چگونه داده‌ها را بر اساس برجسب‌ها یا خروجی‌هایی که تعریف شده است، جدا کند [۹]. از آنجائیکه تابع هسته در مدل SVM، نتایج متفاوتی را بیان می‌کند، با بررسی هر چهار تابع هسته عملکرد آنها نیز با هم مقایسه گردید. در این مرحله، تمام ۴۴ ویژگی استخراج شده در مرحله قبل، بعنوان ورودی مدل و مقادیر X ، و کلاس نمونه‌ها بعنوان جواب مدل در نظر گرفته شد. از آنجائیکه با کاهش ویژگی‌های ورودی مدل، دقت آن کاهش پیدا می‌کرد، عملیات کاهش ویژگی اعمال نگردید. البته در تحقیقات مشابه نیز از ۳۵ ویژگی بعنوان ورودی مدل استفاده گردیده است [۱].

جدول ۱: ویژگی‌های استخراج شده از ماتریس GLRM و روابط آنها

رابطه	ویژگی	ردیف
$\sum_i \sum_j (Q(i,j)/j^2) / S$	Short run	۱
$\sum_i \sum_j (j^2 Q(i,j)) / S$	Long run	۲
$\sum_i (\sum_j Q(i,j))^2 / S$	Gray level non-uniformity	۳
$\sum_j (\sum_i Q(i,j))^2 / S$	Run length non-uniformity	۴
$\sum_i \sum_j S/j Q(i,j)$	Run ratio	۵
$\sum_i \sum_j Q(i,j) / Si^2$	Low gray level run	۶
$\sum_i \sum_j i^2 Q(i,j) / S$	High gray level run	۷
$\sum_i \sum_j Q(i,j) / Sj^2 i^2$	Short run low gray level	۸
$\sum_i \sum_j i^2 Q(i,j) / Sj^2$	Short run high gray level	۹
$\sum_i \sum_j j^2 Q(i,j) / Si^2$	Long run low gray level	۱۰
$\sum_i \sum_j i^2 j^2 Q(i,j) / S$	Long run high gray level	۱۱

که در این روابط $Q(i, j)$ ماتریس GLRM، i مقدار سطح خاکستری، z طول اجرا و S مجموع مقادیر ماتریس GLRM می‌باشند.

تحلیل نتایج

برای بررسی نتایج مختلف طبقه‌بندی کننده SVM، ابتدا مقادیر ضریب تبیین برای سه حالت واسنجی (Cal)، اعتبارسنجی (CV) و پیشگویی (Pre) استخراج و با هم مقایسه گردید. در ادامه برای بررسی بیشتر نتایج تحقیق، با تشکیل ماتریس اغتشاش برای بهترین حالت، مقادیر نرخ کلاس بندی صحیح^۱ (CCR)، حساسیت^۲ و ویژگی^۳ استخراج و تحلیل شد. CCR، نشان دهنده درصد جداسازی و تشخیص صحیح کلاس نمونه‌ها می‌باشد. حساسیت و ویژگی دو پارامتر اندازه‌گیری مهم برای بررسی مدل‌های کلاس بندی می‌باشند. تعریف و کاربرد این پارامترها مشابه ماتریس اغتشاش در مدل‌های کلاس بندی نمونه‌ها می‌باشد. حساسیت کلاس I عبارتست از نسبتی از نمونه‌های کلاس I که به عنوان کلاس I کلاس بندی می‌شوند. ویژگی کلاس I نیز نسبتی از نمونه‌های کلاس II که به اشتباه به عنوان کلاس I کلاس بندی شده‌اند می‌باشد. مقادیر حساسیت و ویژگی طبق روابط ۱ و ۲ قابل محاسبه می‌باشند [۱۰].

$$\text{حساسیت} = \frac{\text{number of True Positives}}{\text{number of Positives}} = \text{Probability of Positive test} \quad (1)$$

$$\text{ویژگی} = \frac{\text{number of True Negatives}}{\text{number of Negatives}} = \text{Probability of Negative test} \quad (2)$$

در این مدل سازی، ۷۰٪ داده‌ها برای آموزش و ۳۰٪ مابقی برای آزمون مدل استفاده گردید. تمام مراحل پردازش تصویر و استخراج ویژگی‌ها در زبان برنامه نویسی متلب ۲۰۱۸، و مدل سازی SVM در برنامه The Unscrambler X 10.4 انجام گرفت.

نتایج و بحث

نتایج حاصل از طبقه‌بندی کننده SVM در جدول ۲ گزارش شده است. مدل SVM در چهار kernel function مختلف بنام‌های Polynomial، linear، Radial basis function و Sigmoid اجرا شد. همانگونه که بخش قبلی اشاره شد، ۷۰٪ نمونه‌ها بصورت اتفاقی به آموزش مدل و ۳۰٪ مابقی نیز به آزمون مدل اختصاص داده شد. نتایج نشان داد، مدل SVM با تابع هسته Linear و Polynomial بهترین نتیجه را از ویژگی‌های استخراج شده با الگوریتم GLRM با دقت ۱۰۰٪ برای مرحله آموزش و با دقت ۹۷/۷۸٪ برای مرحله آزمون مدل بدست آورده است. نتایج جدول ۲ نشان دهنده عملکرد یکسان هر دو تابع مرکزی Linear و Polynomial می‌باشد. در حالیکه دو تابع دیگر نتایج قابل قبولی ارائه ندادند. توابع استفاده شده، به منظور ایجاد مرز بین کلاس‌ها استفاده می‌گردد که مرز خطی و چندجمله‌ای بهترین تفکیک بین کلاس‌های مختلف گندم را از خود نشان داده‌اند. نزدیکی مقادیر واسنجی، اعتبارسنجی و پیش‌بینی مدل، بیانگر قابل اعتماد بودن مدل است.

¹ Correct Classification Rate

² Sensitivity

³ Specificity

جدول ۲: مقادیر ضریب تبیین طبقه بندی کننده SVM بر روی ویژگی‌های GLRM

مدل	تابع هسته	R2		
		Pre	CV	Cal
SVM	Linear	۹۷/۷۸	۹۸/۱۰	۱۰۰
	Polynomial	۹۷/۷۸	۹۸/۱۰	۱۰۰
	Radial basis function	۳۳/۳۳	۳۳/۳۳	۰
	Sigmoid	۳۳/۳۳	۳۳/۳۳	۳۳/۳۳

شایان ذکر است که در مدل SVM-Polynomial، از طبقه بندی کننده با مرتبه ۳ به منظور جداسازی و تفکیک کلاس‌ها استفاده گردید که ماتریس اغتشاش و مقادیر حساسیت، ویژگی و CCR آن در جدول ۳ گزارش شده است. همانگونه که در جدول ۳ آورده شده است، در مرحله آموزش، هر سه رقم گندم انتخابی با موفقیت ۱۰۰٪ از هم تفکیک گردیده است. و حتی بر اساس مقادیر حساسیت و ویژگی هر رقم، مدل توانسته است ارقام غیر کلاس مورد نظر را نیز با دقت ۱۰۰٪ تشخیص دهد. در مرحله آزمون مدل نیز که با استفاده از نمونه‌های تست اجرا گردیده است، نرخ کلاس بندی صحیح مدل برابر با ۹۷/۹۲، بدست آمد. برای رقم صدرا هر سه پارامتر اندازه گیری برابر ۱۰۰٪ محاسبه شد. ولی برای ارقام هما و سرداری نتایج پایین تر ولی در عین حال قابل قبولی بدست آمد. بطوریکه میانگین مقادیر حساسیت و ویژگی محاسبه شده برای کل ارقام بالای ۹۷/۷۵٪ گزارش گردید. تحقیق دیگری با استفاده از Dense Scale Invariant Features (DSIFT) بر روی دانه‌های گندم انجام شده بود که با مدل سازی SVM دقت 88.33٪ گزارش گردیده است که ضعیف تر از نتایج این تحقیق می باشد [۹]. از آنجائیکه با کاهش ویژگی‌ها مقادیر بدست آمده نیز کاهش پیدا می کند، بدین منظور کل ۴۴ ویژگی استخراج شده در مدل استفاده گردید. البته در تحقیقات دیگری نیز علی رغم استخراج تعداد بالای ویژگی، از تعداد ۳۵ ویژگی برای مدلسازی استفاده گردیده است که تفاوت چندانی با تحقیق حاضر ندارد [۱].

جدول ۳: ماتریس اغتشاش طبقه بندی کننده SVM-Polynomial و نتایج آماری آن

GLRM Polynomial		رقم	هما	صدرا	سرداری	میانگین
آموزش	هما	۳۵	۰	۰	۰	-
	صدرا	۰	۳۵	۰	۰	-
	سرداری	۰	۰	۳۵	۰	-
آزمون	حساسیت (%)	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	ویژگی (%)	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	CCR (%)	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	هما	۱۴	۰	۱	۰	-
	صدرا	۰	۱۵	۰	۰	-
	سرداری	۰	۰	۱۵	۰	-
آموزش	حساسیت (%)	۹۳/۳۳	۱۰۰	۱۰۰	۱۰۰	۹۷/۷۸
	ویژگی (%)	۹۶/۷۷	۱۰۰	۱۰۰	۱۰۰	۹۷/۸۵
	CCR (%)	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۷/۹۲

جمع بندی

در سال‌های اخیر، روش بینایی ماشین با کمک از روش‌های مختلف پردازش تصویر به عنوان یک روش غیر تهاجمی کاربردهای زیادی را در زمینه صنعت غذایی و محصولات کشاورزی داشته است. این روش با بررسی برخی ویژگی‌ها از جمله، رنگ، شکل، اندازه و بافت کیفیت سنجی و تعیین طبقه و کلاس محصول نهایی را انجام داده است. در این تحقیق نیز با بهره‌گیری از توانایی روش بینایی ماشین و استخراج ویژگی‌های GLRM که مرتبط با بافت تصاویر می‌باشد، اقدام به طبقه‌بندی ۳ رقم گندم مورد کاشت در منطقه شمالغرب ایران شد. از روش ماشین بردار پشتیبان نیز جهت مدل‌سازی با نظارت و بررسی نتایج استفاده گردید. نتایج مدل‌سازی SVM نشان دهنده عملکرد بسیار بالای ویژگی‌های GLRM با تابع مرکزی خطی و چندجمله‌ای نسبت به دیگر توابع مرکزی بود. به منظور بررسی دقیق‌تر نتایج تحقیق از پارامترهای آماری حساسیت، ویژگی و نرخ جداسازی صحیح ماتریس اغتشاش نمونه‌ها استفاده گردید. نتایج نشان داد که ویژگی‌های بافت استخراج شده با استفاده از الگوریتم GLRM توانایی بسیار بالایی در تشخیص ارقام مختلف گندم دارد و می‌تواند به عنوان یک روش مورد اعتماد استفاده شود.

مراجع:

۱. فاضل نیاری، ض.، افکاری سیاح، ا. ح. و عباسپور گیلانده، ی. ۱۳۹۸. تعیین ویژگی‌ها و مدل بهینه به منظور طبقه‌بندی اجزای کیفی گندم بذری با استفاده از پردازش تصاویر دوربین دیجیتال صنعتی. تحقیقات سامانه‌ها و مکانیزاسیون کشاورزی ۲۰ (۷۳)، ۱-۱۸.
۲. گلپور، ا.، امیری پریان، ج.، امیری چایجان، ر. و خزائی، ج. ۱۳۹۴. تشخیص ارقام شلتوک، برنج قهوه‌ای و سفید بر اساس ویژگی‌های بافتی تصویر و شبکه عصبی مصنوعی. ماشین‌های کشاورزی. ۱(۱)، ۷۳-۸۱.
3. Kaya, E., and Saritas, I. 2019. Towards a real-time sorting system: Identification of vitreous durum wheat kernels using ANN based on their morphological, color, wavelet and gaborlet features. Computers and Electronics in Agriculture, 166(February). <https://doi.org/10.1016/j.compag.2019.105016>
4. Khojastehnazhand, M., and Ramezani, H. 2020. Machine vision system for classification of bulk raisins using texture features. Journal of Food Engineering, 271, p.109864.
5. Khojastehnazhand, M., Mohammadi, V., and Minaei, S. 2019. Maturity detection and volume estimation of apricot using image processing technique. Scientia Horticulturae, 251:247-251.
6. Koklu, M., and Ozkan, I.A. 2020. Multiclass classification of dry beans using computer vision and machine learning techniques. Computers and Electronics in Agriculture, 174105507.
7. Lu, Y. and Lu, R. 2019. Structured-illumination reflectance imaging for the detection of defects in fruit: Analysis of resolution, contrast and depth-resolving features. Biosystems Engineering, 180:1-15.
8. Manickavasagan, A., Sathya, G., and Jayas, D.S. 2008. Comparison of illuminations to identify wheat classes using monochrome images. Computers and Electronics in Agriculture, 63: 237-244.

9. Olgun, M., Onarcan, A. O., Özkan, K., Işık, Ş., Sezer, O., Özgişi, K., and Koyuncu, O. 2016. Wheat grain classification by using dense SIFT features with SVM classifier. *Computers and Electronics in Agriculture*, 122: 185–190. <https://doi.org/10.1016/j.compag.2016.01.033>
10. Parikh, R., Mathai, A., Parikh, S., Sekhar, G. C., and Thomas, R. 2008. Understanding and using sensitivity, specificity and predictive values. *Indian journal of ophthalmology*, 56(1), 45.
11. Pourreza, A., Pourreza, H., Abbaspour-Fard, M. H., and Sadrnia, H. 2012. Identification of nine Iranian wheat seed varieties by textural analysis with image processing. *Computers and Electronics in Agriculture*, 83: 102–108. <https://doi.org/10.1016/j.compag.2012.02.005>
12. Zhang, L., Sun, H., Rao, Z., and Ji, H. 2020. Non-destructive identification of slightly sprouted wheat kernels using hyperspectral data on both sides of wheat kernels. *Biosystems Engineering*, 200: 188–199. <https://doi.org/10.1016/j.biosystemseng.2020.10.004>

Combination of Support Vector Machine with GLRM Features for Classification of Three Wheat Varieties

Mostafa Khojastehnazhand^{1*}, Mozaffar Roostaei²

1. Mechanical Engineering Department, University of Bonab, Bonab, 5551761167, Iran;
2. Dryland Agricultural Research Institute, Agricultural Extension, Education and Research Organization (AREEO), Maraghe, Iran;

Abstract

Wheat is one of the most important and strategic agricultural products that plays an important role in supplying the human food chain. In the meantime, based on climatic conditions, special varieties are proposed for cultivation in each region in order to increase the quality of the final product and increase the field efficiency. In traditional methods, experts are usually employed for differentiation and classification. However, they could make mistake due to low speed, fatigue, and subjectivity. To solve this problem, non-destructive methods such as machine vision are used. In this research, using machine vision method, texture features were extracted by GLRM algorithm in four directions of zero, 45, 90 and 135 degrees. By forming the database, three different varieties (Homa, Sadra and Sardari) were classified by support vector machine classifier (SVM). The results showed that the SVM model with a linear or polynomial kernel functions can identify and classify all three varieties of wheat with high accuracy of 97%. The sensitivity, specificity and correct classification rate (CCR) of all three varieties were also above 97%, which indicates the high accuracy of the SVM model on the GLRM features. The results indicate the very high capability of the machine vision method in classifying and identifying different wheat cultivars and can be used as a reliable method.

Key words: Image processing, Machine vision, Texture, Feature, Wheat

*Corresponding author

E-mail: khojasteh@ubonab.ac.ir