تشخیص کلزا از گیاهان هرز بر اساس ویژگی‌های رنگ و شکل برگ با استفاده از شبکه عصبی

سید مرتضی خلیلی[۱]، علیرضا رضائی[۲*]، علی حاجی احمد[۳]، نگین امیری[۴]

۱- دانشجوی کارشناسی ارشد، گروه مهندسی هوافضا، دانشکده علوم و فنون نوین، دانشگاه تهران، تهران، ایران

۲- عضو هئیت علمی، گروه مهندسی سیستم و مکاترونیک، دانشکده علوم و فنون نوین، دانشگاه تهران، تهران، ایران

۳- عضو هیئت علمی، گروه مهندسی ماشین‌های کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران

۴- دانشجوی کارشناسی ارشد، گروه مهندسی برق، دانشگاه تفرش، تفرش، ایران

* ایمیل نویسنده مسئول: arrezaee@ut.ac.ir

چکیده:

شناسایی ارقام گوناگون گیاهان، کاربردهای فراوانی ازجمله در به‌نژادی و تفکیک محصولات دارد. روش معمول برای انجام این عمل، بررسی چشمی برگ‌ها و میوه‌های گیاهان است که این کار به دلیل وقت‌گیر بودن و هزینه بالا در زمین‌های بزرگ مقرون‌به‌صرفه نیست. شناسایی نمونه‌ها و طبقه‌بندی آن‌ها با استفاده از بینایی ماشین می‌تواند سریع‌تر و با هزینه کمتری انجام شود. در این مقاله از ویژگی‌های رنگ و شکل برگ گیاه کلزا برای تشخیص آن از سایر محصولات و به‌ویژه گیاهان هرز استفاده شد. ابتدا تصاویری از برگ گیاه کلزا و گیاهان هرز آن در مراحل مختلف رشد تهیه شد. سپس این تصاویر به همراه تصاویر اخذشده از برگ سایر گیاهان از یک مجموعه داده معتبر به‌عنوان داده‌های ورودی در نظر گرفته شد. در مرحله بعد ویژگی‌های شکل و رنگ از برگ گیاه کلزا و برگ سایر گیاهان استخراج شد و سپس این ویژگی‌ها برای آموزش به چندین شبکه عصبی با ساختارهای مختلف داده شد. پس از آموزش شبکه‌ها برای آزمون شبکه نیز از داده‌های مشابه تصاویر آموزشی، یعنی تصاویر برگ گیاه کلزا و سایر گیاهان غیر کلزا استفاده شد. نتایج نشان داد که بهترین سیستم در بین شبکه‌های مورداستفاده در این آزمایش یک شبکه عصبی پرسپترون دولایه با ۱۵ نورون در لایه مخفی اول و ۱۰ نورون در لایه مخفی دوم بود. نتایج حاصل از روش پیشنهادی میزان صحت ۹۷٪ را در شناسایی کلزا نشان داد که بیانگر کاربردی بودن روش پیشنهادی در تشخیص محصول کلزا می‌باشد.

واژه‌های کلیدی: بینایی ماشین، تشخیص خودکار کلزا، شبکه عصبی، ویژگی‌های شکل و رنگ.

مقدمه

استفاده از بینایی ماشین در سال‌های اخیر به‌طور گسترده‌ای در زمینه‌های گوناگون کشاورزی گسترش‌یافته است. از مزایای این فن‌آوری در مقایسه با روش‌های سنتی، غیر مخرب بودن، هزینهٔ کمتر، دقت بالا و نیاز کمتر به نیروی انسانی متخصص است (Riquelme *et al*., 2008). یکی از کاربردهای مهم بینایی ماشین طبقه‌بندی محصولات ازنظر شکل و اندازهٔ آن‌ها می‌باشد که می‌تواند در تشخیص محصولات مختلف و تفکیک آن‌ها از هم به کار رود (Abdullah *et al*., 2006). از مناسب‌ترین روش‌های طبقه‌بندی محصولات، طبقه‌بندی آن‌ها بر اساس تصویر برگ‌ها می‌باشد؛ زیرا نمونه‌گیری و گرفتن تصویر از آن‌ها کم‌هزینه‌تر و راحت‌تر از روش‌های مشابه است. پس از اخذ تصاویر و انتقال به رایانه می‌توان از تکنیک‌های پردازش تصویر برای استخراج ویژگی‌های آن استفاده نمود. روش‌های مختلفی برای نحوه استخراج این ویژگی‌ها، اندازه آن‌ها و به‌کارگیری آن‌ها در شناسایی الگو انجام‌شده است (Wu *et al*., 2007). ازجمله روش‌های مورداستفاده می‌توان به روش‌های ریخت‌شناسی[1] و مولکولی اشاره نمود که استفاده از خواص ریخت‌شناسی به دلیل این‌که تابع عوامل محیطی‌اند، دقیق نیستند و روش‌های مولکولی نیز باوجود دقت بالا بسیار پرهزینه و زمان‌بر هستند (Xing *et al*., 2007). لذا لازم است تا روش‌های جدیدتری معرفی‌شده و یا روش‌های قبلی بهبود یابند.

مقایسه شباهت بین ویژگی‌ها برای طبقه‌بندی گیاهان (Fu and Chi, 2003)، استفاده از استخوان‌بندی[2] برگ یا به‌کارگیری تبدیل موجک[3] و درون‌یابی گوسی[4] (Gu *et al*., 2005)؛ استفاده از یک مرکز میانه متحرک[5] (Wang *et al*., 2005) و تطبیق شکل برگ‌ها (Du *et al*., 2006) از روش‌های مورداستفاده تاکنون، برای طبقه‌بندی بوده است. همچنین در برخی پژوهش‌ها از تعدادی ویژگی از پیش تعریف‌شده استفاده‌شده است (Zhenjiang *et al*., 2006). بعد از استخراج ویژگی‌ها باید به نحوی از آن‌ها برای تشخیص بهره برد. به همین دلیل رویکردهای متفاوتی در استفاده از این ویژگی‌های استخراجی به وجود آمده است؛ مانند استفاده از K اُمین نزدیک‌ترین همسایه[6]، سامانه‌های خبره[7] و بهره‌گیری از شبکه‌های عصبی مصنوعی[8] که برخی از روش‌های مورداستفاده می‌باشند. برخی از این روش‌ها نواقصی دارند مثلاً روی ویژگی‌های خاصی قابلیت اجرا دارند؛ و یا برخی دیگر شباهت بین ویژگی‌ها را مقایسه می‌کنند که نیاز به پیش‌پردازش و انجام تنظیمات دستی توسط کاربر را دارند. در بین رویکردهای مختلف سریع‌ترین و دقیق‌ترین عملکرد در طبقه‌بندی مربوط به شبکه‌های عصبی است که کاربرد گسترده‌تری دارند.

---

[1] Morphology
[2] Skeleton
[3] Wavelet transform
[4] Gaussian interpolation
[5] Moving Median Center (MMC)
[6] K-Nearest Neighbor (K-NN)
[7] Expert system
[8] Artificial Neural Network (ANN)

از طرفی استفاده از روغن‌های گیاهی به‌ویژه روغن کلزا روزبه‌روز در حال افزایش است و زمین‌های کشاورزی اختصاص داده به این محصول نیز به‌طور سالانه در حال گسترش هستند (Rapeseed,2015). کلزا یکی از مهم‌ترین دانه‌های روغنی در جهان است (Lu *et al*., 2014)؛ که دارای طیف نسبتاً وسیعی از سازگاری اقلیمی است (Rapeseed,2015). روغن کلزا به دلیل مقدار بسیار پایین اسید اروسیک و گلوکز آن در بازارهای سراسر جهان تقاضای زیادی دارد و درمجموع سومین روغن نباتی معروف در جهان است (Canola,2015). در ایران دانه‌های روغنی عمده و تأمین‌کننده روغن خام داخلی شامل سویا، آفتابگردان و پنبه‌دانه می‌باشد و سایر دانه‌های روغنی سهم ناچیزی را تشکیل می‌دهند. در چند سال گذشته با توجه به ویژگی‌های خاص گیاه کلزا و سازگاری آن با شرایط آب و هوایی اکثر نقاط کشور و همچنین به دلیل توجه بیشتر مسئولان ذی‌ربط به توسعه کشت کلزا، تولید آن افزایش‌یافته است (معاونت امور تولیدات گیاهی، ۱۳۹۳). کاربرد صنعتی این محصول باعث شده تا به‌طور معمول در سطح وسیع کشت شود که این موضوع ضرورت مدیریت صحیح زمین‌های کشاورزی و استفاده از فناوری‌های نوین را برای این محصول بارزتر نموده است (Bairwa *et al*., 2014).

یکی از عوامل محدودکننده کشت کلزا وجود گیاهان هرز است که اغلب با کلزا هم‌خانواده هستند و در طول دوره رشد با گیاه کلزا رقابت تنگاتنگی داشته و بر عملکرد آن تأثیر می‌گذارند (معادی و همکارن ۱۳۹۴). لذا تشخیص گیاهان هرز به‌منظور مبارزه بعد از کاشت و استفاده از علف‌کش مناسب تأثیر بسزایی در عملکرد محصول خواهد داشت.

در ادامه مروری بر پیشینه پژوهش‌های مشابه در تشخیص محصولات انجام‌شده است. در بخش دوم نحوه اخذ و جمع‌آوری تصاویر برگ‌ها ذکرشده و در ادامه آن نیز به تشریح روش مورداستفاده پرداخته‌شده است. در همین راستا تئوری روش، چگونگی جداسازی برگ از پس‌زمینه تصویر و استخراج ویژگی‌های آن توسط بینایی ماشین شرح داده است. در بخش سوم ساختارهای مختلف روش پیشنهادی مورد تجزیه‌وتحلیل قرارگرفته و در بخش چهارم نیز در مورد نتایج حاصل بحث شده و بهترین ساختار شبکه عصبی برای کاربرد حاضر معرفی‌شده است. در انتها کارهای پیشنهادی برای بهبود و گسترش کاربرد روش پیشنهادی در آینده بیان‌شده است.

پیشینه پژوهش

روش‌های گوناگونی برای شناسایی گیاهان از روی برگ آن‌ها توسط پژوهشگران مورداستفاده قرارگرفته است که ازجمله روش‌های پرکاربرد استفاده از ویژگی‌های شکل، رنگ و بافت می‌باشند. در همین راستا برخی روش‌های ابتکاری نیز مورداستفاده قرارگرفته است، نظیر استفاده از ممنتوم ثابت برای فام رنگ[1] و یا تبدیل فوریه قطبی که عملکرد بهتری از ممنتوم ثابت داشته است (Kadir *et al*., 2011). در تحقیقی برای بررسی خرابی سیب ویژگی‌های رنگ، بافت و طیف برای هر پیکسل از تصویر با استفاده از پنجره هم‌پوشان و غیر هم‌پوشان استخراج‌شده و طبقه‌بندی پیکسلی نیز بررسی‌شده است. کلاس‌های طبقه‌بندی عبارت‌اند از سالم، خراب، دم و کاسبرگ و برای طبقه‌بندی پیکسلی تصویر سیب از شبکه عصبی پرسپترون استفاده‌شده است (Unay and

[1] Hue

Gosselin, 2002). در پژوهشی دیگر واریته‌های گیاهان با آنالیز تصویر برگ گیاهان شناسایی شدند. در آنالیز تصاویر از ماتریس هم رویدادی[1] استفاده‌شده و دقت تشخیص نیز ۹۱ درصد گزارش‌شده است (Tsheko, 2002). در تحقیق دیگر شش نوع دانه برنج با استخراج هفت ویژگی رنگی و ۱۴ ویژگی ریخت‌شناسی به‌دست‌آمده، تشخیص داده‌شده است. دقت کل حاصل در تفکیک واریته‌ها برای این روش ۸۴٫۸۳ درصد بوده است (Liu *et al.*, 2005). استفاده از ویژگی‌های نسبت ابعاد، دندانه برگ، رگ برگ و سه ممنتوم ثابت در شناسایی برگ یکی دیگر از روش‌های مورداستفاده بوده است (Wu *et al.*, 2006). در پژوهشی مشابه از تقریب چندضلعی شکل برگ و تطبیق این شکل‌ها استفاده شد (Du *et al.*, 2006). در پژوهشی دیگر گندم را با استفاده از تصاویر طیف باند X و خواص ریخت‌شناسی و با استفاده از ممان‌های شکل، خصوصیات ساختاری و ممان‌های ساختاری به‌دست‌آمده از آن طبقه‌بندی نموده‌اند. بهترین نتیجه برای بالاترین رطوبتی بود که تصاویر در آن اخذشده بود و عملکرد ۹۲٫۸ درصد را داشت (Neethirajan *et al.*, 2006). ترکیب ویژگی‌های گل و برگ برای طبقه‌بندی گل‌های وحشی با شبکه عصبی و استفاده از شبکه عصبی برای توصیفگر فوریه ویژگی برای طبقه‌بندی انجیر هندی نمونه‌های دیگری از کاربرد شبکه‌های عصبی در طبقه‌بندی می‌باشند(Wu *et al.*, 2007). در پژوهشی جامع برای جداسازی ۳۲ گونه گیاهی تعداد زیادی از ویژگی‌های برگ‌های آن‌ها استخراج‌شده و به کمک تحلیل مؤلفه اساسی[2] پنج ویژگی از بین آن‌ها برای تفکیک انتخاب‌شده است. نتایج دقت حدود ۹۰ درصد را در جداسازی نشان می‌دهد (Wu *et al.*, 2007). در پژوهشی ژنو تیپ‌های گوناگون گردو با روش بینایی ماشین تشخیص داده شد. در این تحقیق از روش شبکه عصبی مصنوعی و خواص رنگی و ریخت‌شناسی برای تشخیص ژنو تیپ‌ها استفاده شد و شبکه عصبی مصنوعی دقت ۹۴ درصد را در بهترین حالت برای طبقه‌بندی ارائه داد (Mahmoudi *et al.*, 2010). استفاده از ماشین بردار پشتیبان[3] و جداساز آدابوست[4] برای تفکیک علف هرز از گیاه کلزا و گندم کاربردی مشابه پژوهش انجام‌شده حاضر است که برای روش آدابوست با نرخ خطای متوسط ۲۰٫۴۵ درصد نتایج حاصل ۳٫۲۹ درصد دقیق‌تر از جداساز بیزین[5] با ۲۳٫۷۴ درصد نرخ خطای میانگین و ۰٫۶۲ درصد دقیق‌تر از ماشین بردار پشتیبان با ۲۱٫۰۷ درصد نرخ خطای میانگین برای گیاه کلزا بود (Sunil *et al.*, 2010). در تحقیق دیگری علاوه بر استفاده از شکل برگ و بافت رگ برگ، از ویژگی‌های رنگ برگ نیز برای تفکیک به کمک شبکه عصبی استفاده شد (Kadir *et al.*, 2011). استفاده از ممنتوم ثابت برای ۱۰ گونه گیاهی به‌منظور تفکیک آن‌ها با کمک شبکه عصبی و بدون مدنظر قرار دادن ویژگی رنگی، روش دیگر مورداستفاده بوده است (Zulkifli *et al.*, 2011).

در پژوهش‌های انجام‌شده سنجنده‌های مختلفی مانند تصویربرداری فوق طیفی، تصویربرداری رنگی، تصویربرداری مادون‌قرمز و تصویربرداری با اشعه ایکس برای اخذ تصاویر استفاده‌شده است. همچنین جداسازهای مختلفی برای شناسایی الگو از قبیل شبکه-

[1] Co-occurrence matrix
[2] PCA: Principal Component Analysis
[3] Support Vector Machine (SVM)
[4] Adaboost Classifier
[5] Bayesian Classifier

های عصبی مصنوعی، ماشین بردار پشتیبان و جداساز بیزین استفاده‌شده است و نشان داده‌شده است که دقت کلی به سیستم سنجنده، ویژگی‌های استخراجی و جداساز شناسایی کننده الگو وابسته است (Sunil *et al*., 2010).

با توجه به مطالعات انجام‌شده مشخص است که یکی از روش‌های قابل‌اعتماد برای تفکیک محصولات کشاورزی تلفیق تکنیک‌های بینایی ماشین و هوش محاسباتی است. بدین ترتیب در پژوهش حاضر برای طبقه‌بندی محصول کلزا از سایر محصولات و به‌ویژه گیاهان هرز موجود در مزرعه پردازش تصویر و روش مدل‌سازی به کمک شبکه عصبی استفاده شد. همچنین با توجه به اینکه برگ گیاهان گوناگون، ویژگی‌های ساختاری متفاوت دارند در پژوهش حاضر روش جدیدی برای شناسایی گیاه کلزا با استفاده از برگ آن ارائه شد. در مطالعات قبلی ویژگی‌های رنگ، ریخت‌شناسی و یا بافت تصاویر استفاده‌شده‌اند. در این پژوهش از دو نوع ویژگی ریخت‌شناسی و رنگ به‌طور همزمان استفاده شد. همچنین برای تفکیک گیاهان از شبکه عصبی مصنوعی با ساختارهای مختلف استفاده شد. برای انجام پژوهش حاضر، در ابتدا برگ‌های گیاه کلزا و گیاهان هرز آن جمع‌آوری شد، سپس تصاویری از این برگ‌ها تهیه شد و پس از جداسازی برگ از زمینه تصویر، ویژگی‌های ریخت‌شناسی و رنگ استخراج و سرانجام با استفاده از سیستم شبکه عصبی ارقام کلزا و غیر کلزا از هم تفکیک شدند. شرح کامل هرکدام از مراحل در ادامه بیان‌شده است.

مواد و روش‌ها

ابتدا برگ گیاه کلزای پائیزه رقم نپتون به همراه برگ گیاهان همجوار و گیاهان هرز به‌عنوان نمونه‌ای از گیاهان غیر کلزا در سه مرحله مختلف رشد شامل مراحل ۸ برگی، روزت و ساقه‌دهی، جمع‌آوری گردید. سپس تصاویری از این برگ‌ها با استفاده از دوربین دیجیتال تهیه شد. این تصاویر به همراه تصاویر اخذشده از مجموعه داده فلاویا[1] (Wu *et al*., 2007) که شامل گیاهان غیر کلزا می‌باشند، کل تصاویر را برای بررسی عملکرد روش پیشنهادی شکل می‌دهند.

نمونه‌های برگ استفاده‌شده در این تحقیق در بازه زمانی پائیز و زمستان سال ۱۳۹۴ از مزرعه‌ای واقع در محمدآباد قزوین جمع‌آوری شدند. نمونه‌های برگ کلزای انتخاب‌شده از رقم فرانسوی نپتون به‌طور تصادفی از چند جای مزرعه انتخاب شد. شکل ۱ نمونه‌ای از تصاویر برگ کلزا را نمایش می‌دهد.

[1] Flavia dataset

شکل ۱. تصویر برگ کلزا رقم نپتون

به‌طورکلی ۱۸۰ نمونه برگ شامل ۹۰ نمونه برگ کلزا و ۹۰ نمونه برگ غیر کلزا انتخاب شد. شکل ۲ نیز نمونه‌ای از برگ غیر کلزا موجود در مجموعه داده فلاویا را نمایش می‌دهد.

شکل ۲. یک نمونه از تصاویر برگ غیر کلزا

جداسازی برگ‌ها

بخش‌بندی، تصویر را به ناحیه‌های سازنده‌ی آن یا اشیای مختلف تقسیم می‌کند و از مهم‌ترین مراحل پردازش تصاویر است. روش‌های گوناگونی برای بخش‌بندی وجود دارد. روش‌های مبتنی بر حد آستانه، لبه یابی و ناحیه، روش‌های معمول در بخش‌بندی تصاویر هستند. این کار را می‌توان با آستانه گیری روی تصویر خاکستری برگ انجام داد. لذا در این تحقیق برای کاهش محاسبات و جلوگیری از پردازش تمام تصویر، در مرحله پیش‌پردازش جداسازی برگ‌ها از پس‌زمینه، به کمک حد آستانه انجام شد.

بدین منظور ابتدا هیستوگرام تصویر رسم شد و با توجه به آن روش آستانه گذاری بر اساس رابطه (۱) انجام شد(Gonzalez and Woods, 2008).

$$BW(x,y)=\begin{cases}1 \;\; if \;\; f(x,y)\geq T\\ 0 \;\; if \;\; f(x,y)<T\end{cases} \qquad (۱)$$

طبق رابطه (۱) هر پیکسل از تصویر که شدت نور بیشتر از T داشته باشد شامل پیکسل‌های برگ در کاربرد حاضر است و مقدار یک می‌گیرد. همچنین هر پیکسلی که شدت نور کمتر از T داشته باشد، جزء پس‌زمینه تصویر محسوب می‌شود و مقدار صفر را می‌گیرد.

ازآنجاکه ممکن است بعضی از نواحی داخل سطح برگ‌ها نیز در این روش حذف شوند، باینری کردن تصویر و پر کردن حفره‌های موجود مانع از دست رفتن اطلاعات این نواحی می‌شود. پس از جداسازی تصویر برگ کلزا از پس‌زمینه، عملیات ریخت‌شناسی برای تمایز دقیق نقاط مرزی بین لبه‌ی برگ و پس‌زمینه و پر کردن حفره‌های موجود در تصویر برگ استفاده شد. مجموعه‌ای از عملگرهای باز[1] و بسته[2] به همراه ترکیب‌های متداول گسترش[3] و فرسایش[4] استفاده شد تا تصویر نهایی برگ تنها شامل یک شی باشد و بتوان ویژگی‌های ریخت‌شناسی آن را با دقت بالاتری استخراج نمود. نمونه‌ای از تصویر برگ کلزا مربوط به این مرحله در شکل ۳ قابل‌مشاهده است.

شکل ۳. تصویر برگ کلزا جداسازی شده از پس‌زمینه

برای برگ‌های غیر کلزا نیز عملیات مشابه صورت گرفت. نمونه‌ای از تصویر برگ غیر کلزای جداشده از پس‌زمینه تصویر نیز در شکل ۴ قابل‌مشاهده است.

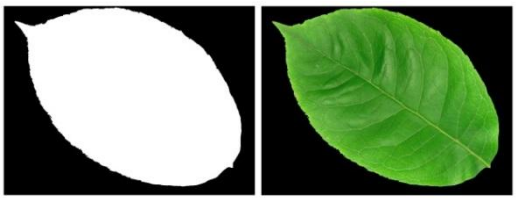

شکل ٤. تصویر برگ غیر کلزا جداسازی شده از پس‌زمینه

استخراج ویژگی

پس از جداسازی برگ‌ها باید ویژگی‌های آن‌ها استخراج شوند. هدف از استخراج ویژگی‌های تصویر، توصیف تصویر بر اساس برخی از توصیفگرهای آماری است تا بتوان آن را با سایر تصاویر مقایسه نمود. به‌طورکلی تصاویر بر اساس سه نوع ویژگی ریخت-شناسی، رنگ و بافت توصیف می‌شوند. به‌طورمعمول در کاربردهای کشاورزی از ویژگی رنگ برای بررسی آفات، بیماری‌های پوستی محصولات، رسیدگی محصول، شناسایی رقم و مانند آن‌ها؛ از ویژگی‌های ریخت‌شناسی شامل قطر، محیط، مساحت،

[1] Opening
[2] Closing
[3] Dilation
[4] Erosion

شکل، حجم و نسبت‌های حاصل از آن‌ها برای درجه‌بندی محصول و از ویژگی‌های بافت نیز در تخمین میزان چروکیدگی روی سطح محصول، شناخت بیماری‌های گیاهی، شناسایی بافت خاک و همچنین در حوزهٔ کاشت و برداشت محصول استفاده می‌شود. به دلیل اینکه در این تحقیق تشخیص از روی ظاهر و ساختار برگ صورت می‌گیرد، سعی شد از ویژگی‌هایی استفاده شود که تفاوت ارقام را به‌خوبی نشان دهد. از طرفی با توجه به گرفته شدن عکس‌ها در فواصل مختلف و به جهت مقاوم نمودن الگوریتم پیشنهادی به این شرایط ویژگی‌هایی انتخاب‌شده‌اند که مستقل از فاصله دوربین از برگ بوده و تنها به نسبت ابعادی برگ در تصویر اشاره می‌کنند. به همین دلیل از هر چهار نوع ویژگی شامل سه ویژگی ریخت‌شناسی و یک ویژگی رنگی برای توصیف تصاویر استفاده شد. در ادامه به توصیف هرکدام از این ویژگی‌ها پرداخته‌شده است.

به‌منظور به دست آوردن خواص ریخت‌شناسی برگ‌ها، در ابتدا تصاویر به تصاویر باینری تبدیل و برچسب‌گذاری شدند. پارامترهای ریخت‌شناسی محاسبه‌شده برای شناسایی ارقام گوناگون برگ‌ها عبارت‌اند از نسبت طول محور اصلی به طول محور فرعی[1] برگ‌ها، وسعت[2] برگ‌ها که عبارت است از نسبت پیکسل‌ها در مستطیل دربرگیرنده برگ به پیکسل‌هایی که در ناحیه موردنظر وجود دارند؛ و یکپارچگی[3] که برابر است با نسبت پیکسل‌ها در پوسته‌ی محدب دربرگیرنده برگ به پیکسل‌هایی که در ناحیه نیز وجود دارند.

از طرف دیگر، رنگ برگ‌های ارقام مختلف با یکدیگر تمایز دارند؛ بنابراین یک توصیفگر رنگ نیز به‌عنوان یک ویژگی مؤثر از نمونه‌های برگ استخراج شد. در استخراج ویژگی‌های رنگی برگ‌ها از رابطه‌ی نرمال شدهٔ (۲) استفاده شد. این رابطه نشان‌دهنده شاخص NDI[4] است که به‌عنوان یک معیار تکمیلی استفاده شد (Payne *et al.*, 2013).

$$NDI = \frac{G - R}{G + R} \qquad (۲)$$

که در آن G بیانگر مقادیر پیکسل‌های مربوط به باند رنگ سبز و R بیانگر مقادیر پیکسل‌های مربوط به باند رنگ قرمز برای یک در تصویر در فضای رنگیRGB[5] می‌باشد. یک سری پارامترهای رنگی مرتبه‌ی اول شامل متوسط[6] و میانه[7] برای این شاخص محاسبه شد که مشخص گردید میانگین معیار بهتری برای مقایسه است و از آن به‌عنوان ویژگی چهارم استفاده شد.

شبکه عصبی

[1] Eccentricity
[2] Extent
[3] Solidity
[4] Normalized Difference Index
[5] Red,Green,Blue
[6] Mean
[7] Median

یکی از روش‌های داده‌کاوی استفاده از شبکه‌های عصبی مصنوعی است که در زمینه‌های گوناگونی از قبیل طبقه‌بندی محصولات کشاورزی کاربرد دارند (Omid *et al.*, 2009). شبکه‌های عصبی از عناصر عملیاتی پایه‌ای ساخته می‌شوند که به‌صورت موازی در کنار هم عمل نموده و از سامانه‌های عصبی زیستی الهام گرفته‌شده‌اند. در طبیعت، عملکرد شبکه‌های عصبی از طریق نحوه‌ی اتصال بین اجزا تعیین می‌شود؛ بنابراین می‌توان یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی ساخت و با تنظیم مقادیر هر اتصال، تحت عنوان وزن اتصال، نحوه ارتباط بین اجزای آن را تعیین نمود (Kohavi and John, 1997). یک شبکه عصبی دارای یک ساختار سه لایه شامل لایه ورودی، لایه مخفی و لایه خروجی می‌باشد. تعداد نورون‌های لایه ورودی، مخفی و خروجی به ترتیب بستگی به تعداد بردار ویژگی‌های ورودی، پیچیدگی مسئله طبقه‌بندی و تعداد کلاس‌های خروجی دارد. بر این اساس ساختارهای مختلفی برای شبکه‌های عصبی مفروض است و یافتن بهترین ساختار در ارتقای نتایج طبقه‌بندی مؤثر است(Haykin, 1998).

لذا در این تحقیق از دو ساختار شبکه عصبی پرسپترون چندلایه[1] و توابع شعاعی پایه[2] استفاده شد. توابع فعال‌سازی مربوط به لایهٔ مخفی و خروجی این شبکه‌ها سیگموئید است. همچنین نمونه‌ها به سه دسته‌ی آموزشی، اعتبارسنجی و آزمون تقسیم شدند. در هر دو مدل شبکه عصبی، از مجموع ۱۸۰ تصویر شامل ۹۰ برگ کلزا و ۹۰ برگ غیر کلزا، تعداد ۱۲۶ عدد یعنی ۷۰ درصد برای آموزش و ۵۴ عدد یعنی ۳۰ درصد برای سنجش سیستم استنتاجی در نظر گرفته شد. گیاهان غیر کلزا شامل گیاهان هرز و برگ‌های مجموعه داده فلاویا هستند. در شبکه عصبی مدل چندلایه، داده سنجش به دو بخش مساوی برای اعتبارسنجی و آزمون تقسیم شد و در مدل توابع شعاعی پایه کل داده سنجش برای آزمون استفاده شد. در هر دو مدل، شبکه‌ها با ۱۰ تکرار تحت آموزش و آزمایش قرار گرفتند. سپس به‌وسیله‌ی میانگین مربعات خطا[3] و درصد نرخ تشخیص صحیح[4] ارزیابی شدند. لذا از رابطه (۳) برای محاسبه خطای شبکه استفاده شد.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(P_i - A_i)^2} \qquad (۳)$$

همچنین برای بررسی عملکرد شبکه عصبی در طبقه‌بندی برگ‌ها و انتخاب بهترین ساختار شبکه در بین ساختارهای گوناگون از شاخص آماری نرخ طبقه‌بندی صحیح با معادلهٔ (۴) استفاده شد(Mollazade *et al.*, 2012).

$$CCR(\%) = \frac{N_r}{N} \times 100 \qquad (۴)$$

در این رابطه در پژوهش حاضر N_r تعداد کلزاهایی است که به‌طور صحیح طبقه‌بندی‌شده‌اند و N تعداد کل کلزاها در یک کلاس مشخص و CCR بیانگر نرخ طبقه‌بندی صحیح است.

[1] MLP: Multilayer Perceptron
[2] RBF: Radial Basis Function
[3] RMSE: Root Mean Square Error
[4] CCR: Correct Classification Rate

نتایج

به دلیل اینکه در شبکه‌های عصبی، نحوهٔ عملکرد داخلی شبکه روشن نیست، برای تعیین ساختار شبکه از آزمون‌وخطا استفاده می‌شود. ازاین‌رو تعدادی از شبکه‌های چندلایه و توابع شعاعی پایه با ساختارهای گوناگون امتحان شدند تا بتوان به بهترین مدل دست‌یافت. همچنین به دلیل انتخاب شدن تصادفی داده‌ها از مجموعه‌های آموزش و سنجش، برای هر ساختار چندین تکرار انجام شد و بهترین نتیجه مدنظر قرار گرفت. نتایج حاصل از آموزش شبکه عصبی مدل‌های توابع شعاعی پایه و پرسپترون چندلایه با سه ساختار مختلف در ادامه شرح داده‌شده است.

در شبکه چندلایه از بین ساختارهای گوناگون تک لایه و دولایه، تعداد نورون‌ها از ۱۰ تا ۱۵ نورون تغییر نموده است و الگوریتم آموزشی مورداستفاده برای تمام حالات نیز لونبرگ–مارکوارت بود. با بررسی ساختارهای متفاوت، ساختار دولایه [۱۵ و ۱۰] با ۱۵ نورون در لایه مخفی اول و ۱۰ نورون در لایه مخفی دوم بهترین عملکرد را با نرخ تشخیص صحیح ۹۷٫۸ درصد و میانگین مربعات خطا ۰٫۲ داشت. بعد از آن ساختار دولایه [۱۰ و ۱۵] با ۱۰ نورون در لایه مخفی اول و ۱۵ نورون در لایه مخفی دوم و مدل شعاعی پایه قرار گرفت. ساختار تک لایه نیز پایین‌ترین عملکرد را در بین ساختارهای موجود داشت. جدول ۱ نرخ تشخیص صحیح برحسب درصد و میانگین مربعات خطا را برای ساختارهای چندلایه در حالت یک‌لایه[۱۵] با ۱۵ نورون در لایه مخفی و حالت دولایه با ساختارهای [۱۵ و ۱۰] و [۱۰ و ۱۵] و همچنین یک مدل از توابع شعاعی پایه را نمایش می‌دهد.

جدول ۱. درصد نرخ تشخیص صحیح و میانگین مربعات خطا برای ساختارهای مختلف شبکه عصبی

	درصد نرخ تشخیص صحیح (CCR)	میانگین مربعات خطا (RMSE)
تک لایه [۱۵]	٪ ۸۵٫۶	۰٫۵۶
دولایه [۱۰ و ۱۵]	٪ ۹۵٫۶	۰٫۲۷
دولایه [۱۵ و ۱۰]	٪ ۹۷٫۸	۰٫۲۰
مدل شعاعی پایه	٪ ۹۴٫۴	۰٫۲۹

پس از انتخاب ساختار بهینهٔ شبکه عصبی، به‌منظور ارزیابی نتایج با استفاده از معادلهٔ (۴) مقدار شاخص آماری نرخ طبقه‌بندی صحیح برای هر کلاس که از ماتریس اغتشاش[1] در جدول ۲ به‌دست‌آمده است، محاسبه شد که نتایج آن در جدول ۳ نمایش داده‌شده است.

جدول ۲. ماتریس اغتشاش به‌دست‌آمده از نتایج شبکه عصبی منتخب برای کل داده‌ها شامل آموزش و سنجش

	مقادیر واقعی

[1] Confusion Matrix

پیش‌بینی شبکه عصبی	کلزا	غیر کلزا	جمع دقت (درصد)
کلزا	۸۷ (٪۴۸,۳)	۱ (٪۰,۶)	۸۸ (٪۹۸,۹)
غیر کلزا	۳ (٪۱,۷)	۸۹ (٪۴۹,۴)	۹۲ (٪۹۶,۷)
دقت (درصد)	٪۹۶,۷	٪۹۸,۹	٪۹۷,۸
خطا (درصد)	(٪۳,۳)	(٪۱,۱)	(٪۲,۲)

بنابراین استفاده از ترکیب ویژگی‌ها توانسته است دقت طبقه‌بندی را بالا ببرد. همچنین نتایج ماتریس اغتشاش و پارامترهای آماری به‌دست‌آمده نشان می‌دهد که استفاده از ویژگی‌های شکل و رنگ و روش طبقه‌بندی هوشمند شبکه عصبی می‌تواند در درجه‌بندی کیفی این محصول بر اساس استانداردهای تعریف‌شده نیز مؤثر باشد.

جدول ۳. نرخ طبقه‌بندی صحیح شبکه عصبی برای دو کلاس کلزا و غیر کلزا در ساختار شبکه‌ی منتخب

	شاخص آماری (CCR%) برای کلاس برگ‌ها	
	کلزا	غیر کلزا
شبکه عصبی دولایه [۱۰ و ۱۵]	۹۶,۷	۹۸,۹

در تحقیقات قبلی از شبکه عصبی به‌منظور طبقه‌بندی کلاس‌های مختلف گیاهان استفاده‌شده است. نرخ خطای میانگین ۲۰,۴۵ درصدی برای جداساز آدابوست[1] و ۲۱,۰۵ درصدی برای ماشین بردار پشتیبان[2] جهت جداسازی گیاه کلزا (Sunil *et al.*, 2010)، دقت ۹۴ درصد برای تشخیص ژنوتیپ‌های گردو با استفاده از الگوریتم مبتنی بر پردازش تصویر و شبکه عصبی (Mahmoudi et al., 2010) و تشخیص واریته‌های برنج با دقت ۹۰,۵ درصد با استفاده از تکنیک‌های پردازش تصویر و شبکه عصبی (Liu et al., 2005) برخی از این نتایج هستند.

به‌منظور ارزیابی عملکرد مدل‌های طبقه‌بندی کننده‌ی پیشنهادی برای گیاه کلزا، نرخ خطای طبقه‌بندی برای هر کلاس و تمام نمونه‌ها محاسبه و مقایسه شده‌اند. نرخ خطا به‌صورت نسبت تعداد نمونه‌های طبقه‌بندی‌شده نادرست به تعداد کل یک مجموعه از نمونه‌ها تعریف‌شده است (Fan *et al.*, 2011). نرخ تشخیص صحیح ۹۷,۸ درصد، نرخ خطا ۲,۲ درصد و میانگین مربعات خطا ۰,۲، نتایج حاصل از طبقه‌بندی با استفاده از ساختار پیشنهادی است که نسبت به روش‌های مورداستفاده در

[1] AdaBoost classifier

[2] Support Vector Machine

پژوهش‌های قبلی، عملکرد بهتری نشـان می‌دهد. در این تحقیق همه الگوریتم‌ها در محـیط نـرم‌افـزار MatLab (نسـخه۸,۶) پیـاده‌سازی شده‌اند.

نتیجه‌گیری

در این پژوهش، روشی جهت شناسایی و تفکیک گیاه کلزای پائیزه از سایر محصولات و گیاهان هرز بر اساس پردازش تصـویر بـا استفاده از ویژگی‌های رنگ و شکل برگ ارائه‌شده است. در الگوریتم پیشنهادی پس از پردازش تصاویر و اسـتخراج ویژگـی‌هـا از شبکه عصبی برای طبقه‌بندی و تفکیک استفاده می‌شود.

نتایج حاصل نشان می‌دهد شبکه عصبی پرسپترون دولایه با روش آموزش لونبرگ-مارکوارت و دسته‌بندی شبکه‌ای در مقایسه بـا سایر ساختارها بالاترین دقت را داشته و درصد تشخیص صحیح ۱۰۰ برای داده‌های آموزش و ۹۲,۳ بـرای داده‌هـای آزمـون بـه ترتیب برای این سیستم استنتاجی به‌دست‌آمده است. درنتیجه سیستم استنتاجی توانسته است کل داده‌ها را با دقـت ۹۷,۸ درصـد تشخیص دهد. نتایج حاصل از این تحقیق علاوه بر تأیید یافته‌های پیشین، دقـت بـالاتری در مقایسـه بـا آن‌هـا دارد. همچنـین الگوریتم پیشنهادی مستقل از فاصله دوربین از برگ بوده و ویژگی‌های شکل استخراج‌شده از برگ‌ها تنها به نسبت ابعادی برگ در تصویر اشاره می‌کند.

با استفاده از نتایج این تحقیق می‌توان نتیجه گرفت که استفاده از ترکیب ویژگی‌های شکل و رنگ در فضاهای رنگی گوناگون و بهره‌گیری از تکنیک‌های هوش محاسباتی همچون شبکه مصنوعی در تشخیص صحیح گیاه کلزا از سـایر محصـولات و گیاهـان هرز، نقش مؤثری دارند. تشخیص ارقام مختلف کلزا و بیماری آن‌ها می‌تواند به فعالیت‌های آینده پژوهشی صورت گیـرد؛ تـا روش ارائه‌شده بهبود داده شود.

سپاسگزاری

در پایان از دانشگاه تهران، شرکت دشت ناز ساری و دفتر خدمات کشاورزی محمدآباد قزوین به خاطر همکاری در پیشبرد این پژوهش قدردانی می‌گردد. همچنین پژوهشگران مراتب قدردانی خود را از کشاورز نمونه زمین موردمطالعه در محمدآباد قزوین، جناب آقای زهرایی اعلام می‌دارند.

منابع

معادی، ب.، کاظم، م.، میرزایی، س.، ۱۳۹۴. زراعت کلزا، اول .ed .تاک، تهران.

معاونت امور تولیدات گیاهی، ۱۳۹۳. وزارت جهاد کشاورزی

URL http://www.agri-jahad.ir/portal/Home/Default.aspx?CategoryID=69901830-8702-4a07-af5b-eb0a2d23d112 (accessed 7.12.15).

Abdullah, M.Z., Mohamad-Saleh, J., Fathinul-Syahir, A.S., Mohd-Azemi, B.M.N., 2006. Discrimination and classification of fresh-cut starfruits (Averrhoa carambola L.)

using automated machine vision system. Journal of Food Engineering. 76, 506–523.

Bairwa, N., Agrawal, N., Gupta, S., 2014. Development of Counting Algorithm for Overlapped Agricultural Products. International Journal of Computer Applications. Appl. 16–19

Canola, 2015, Wikipedia. URL https://fa.wikipedia.org/wiki/کلزا

Du, J.-X., Huang, D.-S., Wang, X.-F., Gu, X., 2006. Computer-aided plant species identification (CAPSI) based on leaf shape matching technique. Trans. Inst. Meas. Control 28, 275–285.

Fan, W., Li, H., Shan, Y., Lv, H., Zhang, H., Liang, Y., 2011. Classification of vinegar samples based on near infrared spectroscopy combined with wavelength selection. Anal. Methods 3, 1872–1876.

Fu, H., Chi, Z., 2003. A two-stage approach for leaf vein extraction, in: Neural Networks and Signal Processing, 2003. Proceedings of the 2003 International Conference on. IEEE, pp. 208–211.

Gonzalez, R.C., Woods, R.E., 2008. Digital Image Processing, 3rd edition, 3rd editio. ed. Prentice Hall.Gu, X., Du, J.-X., Wang, X.-F., 2005. Leaf recognition based on the combination of wavelet transform and gaussian interpolation, in: Advances In Intelligent Computing. Springer, pp. 253–262.

Haykin, S., 1998. NEURAL NETWORKS A Comprehensive Foundation Second Edition, 2nd Editio. ed. Prentice Hall PTR Upper Saddle River, NJ, USA ©1998.

Kadir, A., Nugroho, L.E., Susanto, A., Santosa, P.I., 2011. Leaf Classification Using Shape, Color, and Texture Features. Int. J. Comput. Trends Technol. 225–230.

Kohavi, R., John, G.H., 1997. Wrappers for feature subset selection. Artif. Intell. 97, 273–324.

Liu, Z., Cheng, F., Ying, Y., Rao, X., 2005. Identification of rice seed varieties using neural network. J. Zhejiang Univ. Sci. B 6, 1095.

Lu, Y., Du, C., Yu, C., Zhou, J., 2014. Classifying rapeseed varieties using Fourier transform infrared photoacoustic spectroscopy (FTIR-PAS). Comput. Electron. Agric. 107, 58–63. doi:10.1016/j.compag.2014.06.005

Mahmoudi, M., Khazaei, J., Vahdati, K., Taleb, M., 2010. Walnut Genotype Detection Using Machine Vision Technique, in: The 5th National Congress of Agricultural Machinery And Mechanization. Mashhad (In Farsi).

Mollazade, K., Omid, M., Arefi, A., 2012. Comparing data mining classifiers for grading raisins based on visual features. Comput. Electron. Agric. 84, 124–131.

Neethirajan, S., Karunakaran, C., Symons, S., Jayas, D.S., 2006. Classification of vitreousness in durum wheat using soft X-rays and transmitted light images. Comput. Electron. Agric. 53, 71–78.

Omid, M., Mahmoudi, A., Omid, M.H., 2009. An intelligent system for sorting pistachio nut varieties. Expert Syst. Appl. 36, 11528–11535.

Payne, A.B., Walsh, K.B., Subedi, P.P., Jarvis, D., 2013. Estimation of mango crop yield using image analysis - Segmentation method. Comput. Electron. Agric. 91, 57–64. doi:10.1016/j.compag.2012.11.009

Rapeseed, 2015, Wikipedia. URL https://en.wikipedia.org/wiki/Rapeseed

Riquelme, M.T., Barreiro, P., Ruiz-Altisent, M., Valero, C., 2008. Olive classification according to external damage using image analysis. J. Food Eng. 87, 371–379.

Sunil, K.M., Paul, R.W., Randal, K.T., Guoliang, F., 2010. Adaboost and Support Vector Machine Classifiers for Automatic Weed Control: Canola and Wheat. 2010 Pittsburgh, Pennsylvania, June 20 - June 23, 2010.

Tsheko, R., 2002. Discrimination of Plant Species Using Co Occurrence Matrix of Leaves. Int. Comm. Agric. Eng.

Unay, D., Gosselin, B., 2002. Apple defect detection and quality classification with MLP-Neural networks, in: Proceedings of the ProRISC Workshop on Circuits, Systems and Signal Processing. Citeseer.

Wang, X.-F., Du, J.-X., Zhang, G.-J., 2005. Recognition of leaf images based on shape features using a hypersphere classifier, in: Advances in Intelligent Computing. Springer, pp. 87–96.

Wu, Q., Zhou, C., Wang, C., 2006. Feature extraction and automatic recognition of plant leaf using artificial neural network. Adv. Artif. Intell. 3, 5–12.

Wu, S.G.G., Bao, F.S.S., Xu, E.Y.Y., Wang, Y.-X., Chang, Y., Xiang, Q., 2007. A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network. Int. Symp. Signal Process. Inf. Technol. 1–6. doi:10.1109/ISSPIT.2007.4458016

Xing, J., Saeys, W., De Baerdemaeker, J., 2007. Combination of chemometric tools and image processing for bruise detection on apples. Comput. Electron. Agric. 56, 1–13.

Zhenjiang, M., Gandelin, M.-H., Baozong, Y., 2006. An OOPR-based rose variety

recognition system. Eng. Appl. Artif. Intell. 19, 79–101.

Zulkifli, Z., Saad, P., Mohtar, I.A., 2011. Plant leaf identification using moment invariants & general regression neural network, in: Hybrid Intelligent Systems (HIS), 2011 11th International Conference on. IEEE, pp. 430–435.