

تشخیص خوشه انگور قرمز ایستاده با استفاده از پردازش تصویر و شبکه عصبی

به منظور کاربرد در ربوت برداشت انگور

اکبر نظری چمکی^{*}، داود محمدزمانی^۲، پرویز احمدی‌مقدم^۳ و جلال الدین قضاوی^۴۱- دانشجوی سابق کارشناسی ارشد مهندسی مکانیک ماشین‌های کشاورزی دانشگاه آزاد اسلامی واحد تاکستان
akyred@gmail.com

۲- استادیار، گروه مکانیک ماشین‌های کشاورزی، دانشگاه آزاد اسلامی واحد تاکستان

۳- استادیار، گروه مکانیک ماشین‌های کشاورزی- دانشگاه ارومیه

۴- دانشگاه آزاد اسلامی، واحد بناب، باشگاه پژوهشگران حوان و نخبگان، بناب، ایران

چکیده

در این تحقیق یک سامانه طبقه‌بندی خودکار بر مبنای ماشین بینایی و شبکه‌های عصبی مصنوعی بر اساس رنگ و مؤلفه‌های آن، توسعه داده شد. حدود ۳۰۰ تصویر رقمی از باغات انگور شهرستان ارومیه در شرایط مختلف نوری از ساعت اولیه صبح تا عصر در هوای ابری و آفتابی گرفته شدند. از شبکه عصبی پرسپترون چند لایه با الگوریتم یادگیری پس انتشار خطابه عنوان یکی از ابزارهای هوش مصنوعی برای تشخیص و جداسازی کلاس‌های تصویر استفاده شد. ورودی شبکه، مؤلفه‌های اصلی رنگ (R, G و B) پیکسل‌های تصاویر بوده و در خروجی شبکه عدد یک (۱) به عنوان خوشه انگور قرمز و عدد صفر (۰) به عنوان غیر انگور (برگ، آسمان، شاخه و تنہ) در نظر گرفته شد که در نهایت بعد از آزمون و خطای الگوریتم یادگیری و تعداد نمونه‌های شبکه عصبی مشخص شد که با بکارگیری ۱۳ نمون در لایه مخفی و یک لایه مخفی و الگوریتم یادگیری از نوع Trainlm و تابع انتقال سیگموئیدی، شبکه عصبی با ۹۸ درصد قادر به تشخیص و جداسازی کلاس‌های تصویر می‌باشد. نتایج حاصل از آنالیز تصویر حاکی از وجود دقت بالایی در بخش‌بندی کلاس‌های تصویر بود.

کلمات کلیدی: انگور قرمز، پردازش تصویر، هوش مصنوعی، ماشین بینایی

مقدمه

بر اساس آمار نامه وزارت جهاد کشاورزی سطح زیر کشت انگور در ایران در سال ۱۳۹۰، ۳۰۶ هزار هکتار بوده و با تولید بالغ بر ۳ میلیون تن در مرتبه هفتم جهان و یکی از عمده‌ترین تولیدکنندگان انگور به شمار می‌آید (FAO 2011). برداشت بسیاری از محصولات باغی و بسیاری از میوه‌های گلخانه‌ای نیازمند نیروی انسانی بسیار بوده و در نتیجه هزینه برداشت این محصولات را افزایش خواهد داد. در صورتی که بتوان سامانه‌های برداشت را مکانیزه کرده و از ماشین‌های خودکار برای برداشت محصولات

استفاده کرد میزان زیادی از این هزینه‌ها کاسته شده و در مقابل صرف تولید محصولات بیشتر و با کیفیت‌تر خواهد شد. استفاده از دستگاه‌های مکانیزه کنترل، داشت و برداشت محصول برای گونه‌ای از میوه‌ها که مصرف گسترده‌ای برای مردم دارند مقرر رساند. این کار هم به دلیل تعداد کم کارگران و هم به دلیل اینکه با استفاده از روبوت می‌توان میوه‌ها را با کیفیت صرفه به نظر می‌رسد. این کار هم به دلیل تعداد کم کارگران و هم به دلیل اینکه با استفاده از روبوت می‌توان میوه‌ها را با کیفیت بهتر از درخت جدا کرد، مفید به نظر می‌رسد. تکنیک‌های پردازش رقومی تصویر، ماشین بینایی، هوش مصنوعی (شبکه عصبی) و شاخه‌های وابسته به آنها هر روز جای خود را در بین رشته‌های علوم فنی و مهندسی و از جمله طراحی ماشین‌های کشاورزی باز می‌کنند. از جمله مزیت‌های اصلی این روش‌ها، غیر مخرب بودن^۱ و بلادرنگ بودن^۲ این روش‌ها و کاهش خطای انسانی است.

(Christopher.j.Mills,2005)

رنگ یکی از فاکتورهای بسیار مهم در تشخیص میوه‌هاست. برای تهیه سامانه طبقه‌بندی مناسب بر اساس رنگ دو عامل مهم باید در نظر گرفته شود. نخست اینکه سامانه رنگی برای انواع کلاس‌های متفاوت مورد نظر، برای طبقه‌بندی میوه، دارای مقادیر با فاصله مناسب باشد تا در زمان طبقه‌بندی، تشخیص کلاس‌ها از یکدیگر به سادگی امکان‌پذیر باشد.



شکل ۱: مراحل طی شده برای پروره‌های ماشین بینایی

دوم اینکه سرعت محاسبه فاکتورهای این سامانه رنگی نیاز به زمان زیادی نداشته باشد. به منظور طبقه‌بندی خودکار محصولات کشاورزی می‌توان از سامانه بینایی ماشین استفاده کرد. مراحل استفاده از سامانه بینایی ماشین در شکل ۱ مشاهده می‌شود. تا کنون تحقیقات متفاوتی بر روی برداشت محصولات توسط ماشین‌های بینایی صورت گرفته است. زند و همکاران (۲۰۱۱)، روشی برای آشکارسازی میوه خیار گلخانه‌ای در تصاویر گلخانه‌ای با رهیافت شبکه عصبی پیشنهاد کردند. این شبکه با استفاده از تعدادی تصویر شامل تصاویر خیار و تصاویر غیر خیار و پاسخ‌های مطلوب آنها آموزش داده شد. نواحی به دست آمده از این شبکه منجر به آشکار سازی دقیق مکان خیارها در تصویر شد.

استبان^۳ و همکاران (۲۰۰۹)، یک سامانه بینایی برای درجه بندی انگور در انبار با استفاده از مدل‌های رنگی RGB و HSV و شبکه عصبی پیشنهاد دادند. بهترین نتیجه با استفاده از شبکه‌های سه لایه پنهان به دست آمد که رویکردی از یک رابطه غیر خطی از آنالیز اجزای اصلی و رسیدن به یک میزان موفقیت بیش از ۹۰ درصد در تمام آزمون‌ها را نشان می‌دهد.

زادویان^۴ و همکاران (۲۰۰۵)، توانستند به شناسایی واریته برنج با استفاده تکنیک‌های پردازش تصویر و شبکه عصبی پردازند.

واریته‌های برنج مورد استفاده از ey7954, syz3, xs11, xy5968, xy9308, z903 بودند، از این واریته‌ها ۷ ویژگی رنگ و ۹

¹ Non-Destructive

² Real-Time

³ Esteban

⁴ Zhao-yan

ویژگی مورفولوژیکی بدست آورده شد. از هر واریته حدود ۲۰۰ نمونه برای آموزش شبکه انتخاب شد و بعد از آموزش از ۶۰ نمونه برای تست شبکه استفاده کردند.

گویر و یانگ^۱ (۲۰۰۰)، یک سامانه ماشین بینایی طراحی کردند که مشخصات بافت‌های مختلف گیلاس را تعیین می‌کرد. تصاویر چند طیفی از نمونه‌های گیلاس جمع آوری شد که در محدوده ۶۸۰-۱۲۸۰ نانومتر با فواصل ۴۰ نانومتر بودند. با استفاده از اثرات طیفی بافت‌های مختلف گیلاس در تصاویر، از شبکه‌های عصبی برای طبقه‌بندی استفاده شد. در نهایت نرخ ۷۳٪ برای تشخیص و جداسازی درست بدست آمد.

مجیدی و همکاران (۲۰۰۹)، یک سامانه بینایی ماشین برای روبوت برداشت سیب‌های قرمز و زرد را با استفاده از تصاویر رنگی پیاده‌سازی کردند. نتایج حاصل از آنالیز و طبقه‌بندی تصاویر در شبکه عصبی وجود دقت بالای ۹۷/۵ درصد را نشان داد.

مواد و روش‌ها

تعداد ۳۰۰ عکس از چهار باغ انگور بزرگ از نوع بیدانه قرمز در دو روستای تازه کند و نازلو در شهرستان ارومیه از خوش‌انگور قرمز با استفاده از یک دوربین رقمی CanonPowerShot SX30 IS با تفکیک پذیری ۷ مگا پیکسل تهیه و ذخیره شدند. بر اساس تحقیقات قبلی بهترین ویژگی به منظور طبقه‌بندی تصاویر، آنالیز تصاویر در فضای رنگی و استفاده از ویژگی‌های رنگی تصویر تشخیص داده شد. (پاگولا و همکاران ۲۰۰۸، پیدیپاتی و همکاران ۲۰۰۸). هر یک از کلاس‌های استخراج شده خوش‌انگور قرمز، برگ‌های سبز، آسمان و شاخه‌ها از تفیری آرایه‌های رنگی تصویر، حاصل شدند، به همین علت تصاویر به دست آمده با این روش، دارای مقادیر سطح خاکستری بسیار پایینی می‌باشند. برای حل این مشکل از تصاویر باینری کلاس‌های استخراج شده تصویر به عنوان ورودی الگوریتم استخراج ویژگی‌های کلاس‌های تصویر استفاده شد. به این منظور پس از پردازش مقدماتی تصویر، مقدار میانگین کل پیکسل‌های تشکیل دهنده هر مولفه تصویر بر اساس رابطه ۱ زیر محاسبه شد.

$$A_i = \frac{\sum g_i(x, y)}{N_i} = \frac{1}{m \times n} \sum g_i(x, y) \quad (1)$$

که در آن:

A_i : مقدار میانگین مولفه i ام تصویر، $(x, y)_i$: مقدار سطح خاکستری پیکسل (y, x) در مولفه i ام تصویر، N_i : تعداد کل پیکسل‌های تصویر، m : تعداد سطرهای تصویر و n : تعداد ستون‌های تصویر می‌باشد.

هدف اصلی از استخراج ویژگی، کاهش ابعاد تصویر و متعاقب آن کاهش حجم داده‌های ورودی به سامانه‌های پردازش است. معیار اصلی برای انتخاب بردارهای ویژگی افزایش وجه تمایز^۲ بین بردارهای ویژگی مربوط به کلاس‌های تصویر است؛ یعنی

¹Guyer and Yang
²Discriminatory

عناصر مربوط به بردارهای ویژگی به نحوی بوده که دو بردار از لحاظ جبری متمایز بوده و برابر نباشند. در نهایت با آزمودن ویژگی‌های استخراج شده برای تمامی کلاس‌های یک تصویر و با در نظر گرفتن حافظه در دسترس و قدرت محاسباتی ماشین این مهم حاصل شد که بهترین نتیجه با بردارهای ویژگی 3×1 به دست خواهد آمد، یعنی انتخاب تنها سه ویژگی و آرایش آنها به صورت یک بردار 1×3 به طوری که میزان تمايز بین بردارهای ویژگی مربوط به کلاس‌های مختلف یک تصویر در فضای بردارهای ویژگی را افزایش دهد، کفایت خواهد کرد. در این تحقیق با توجه به تحقیقات سایر محققین و بررسی فضاهای رنگی مختلف، فضای RGB به عنوان مناسب‌ترین فضا برای دسته‌بندی و طبقه‌بندی تصاویر و تشخیص میوه یا غیر میوه بودن، انتخاب گردید. در رنگی RGB به دلیل اینکه مستقیماً تمامی داده‌های موجود وارد شبکه می‌شوند هیچگونه کاهش یا حذف اطلاعات رخ نمی‌دهد. این روش به دلیل اینکه میانگین مولفه‌های اصلی رنگ (R, G, B) پیکسل‌های تصاویر بوده و خروجی شبکه عدد یک (۱) به ورودی هر کدام از شبکه‌ها، میانگین مولفه‌های اصلی رنگ (R, G, B) به عنوان غیر انگور قرمز (برگ، آسمان، شاخه و تنه) می‌باشد. مقدار میانگین مولفه‌های عنوان خوشه انگور قرمز و عدد صفر (۰) به عنوان غیر انگور قرمز (برگ، آسمان، شاخه و تنه) می‌باشد. ماتریس معرفی اصلی هر تصویر همراه با مقدار عدد خروجی که نشانگر انگور یا غیر انگور بودن را نشان می‌دهد، به صورت یک ماتریس معرفی می‌گردد. شبکه طراحی شده در این تحقیق که به منظور طبقه‌بندی و دسته‌بندی کلاس‌های تصویر با استفاده از میانگین مولفه‌های اصلی رنگ (R, G, B) به کار گرفته شد، از نوع شبکه‌های چند لایه پس انتشار برگشتی^۱ است. از الگوریتم‌های آموزشی برای حل گردن کافی در لایه میانی داشته باشد (منهاج ۱۳۸۴). با توجه به اینکه دامنه تابع سیگموئیدی شامل کلیه اعداد حقیقی می‌باشد، در مورد اعداد ورودی به شبکه هیچ محدودیت وجود ندارد. ولی برای جلوگیری از توقف زود هنگام شبکه و همچنین برای جلوگیری از اشباع زود هنگام نمونه‌ها با استفاده از محدوده خطی تابع سیگموئیدی قرار گیرد و این امر به معنی محدود کردن داده‌ها در محدوده [۰, ۱]^۲ و یا به اصطلاح دیگر نرمال کردن^۲ داده‌ها می‌باشد. لذا برای یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی تمامی داده‌ها نرمال سازی شد. روش‌های متفاوتی برای نرمالیزه کردن داده‌ها وجود دارد که در اینجا از رابطه (۲) استفاده شد:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

که در آن: x : مقدار واقعی متغیر، x_{min} : مقدار کمینه در داده‌های ورودی، x_{max} : مقدار بیشینه در داده‌های ورودی

x_{norm} : مقدار نرمال می‌باشد.

¹ Back Propagation

² Normalization

در طول آموزش شبکه از الگوریتم پس انتشارخطا استفاده شد و مقادیر تخمین زده شده توسط شبکه با مقادیر واقعی اندازه‌گیری شده، مقایسه، پس از مقایسه، مقدار خطای محاسبه شده و آموزش شبکه تا جایی ادامه پیدا می‌کند تا خطای کمتر از خطای مورد نظر برای آموزش شبکه باشد. در صورتی که مقدار خطای داده‌های ارزیابی، علیرغم کاهش خطای داده‌های آموزش رو به افزایش باشد در این حالت بیش برآش^۱ اتفاق افتاده است و در صورتیکه خطای شبکه، در طی تکرارهای^۲ متواالی، مقدار یکسانی داشته باشد یا اصطلاحاً خطای شبکه همگرا شود آموزش متوقف می‌شود.

پس از طراحی شبکه عصبی مناسب، برای بررسی میزان دقت مدل‌های ارائه شده برای طبقه‌بندی داده‌ها باید از معیارهای مناسبی استفاده گردد. این معیارها، شاخص‌هایی هستند که می‌تواند کارایی مدل‌ها و همچنین همگرایی شبکه را کنترل کنند. یکی از شاخص‌های کمی که در ارزیابی شبکه‌ها و مدل‌های مختلف مورد استفاده قرار می‌گیرد ضریب همبستگی^۳ (R) می‌باشد که این ضریب توسط رابطه (۳) بیان می‌گردد.

$$R = \frac{\sum(p_i - \bar{P})(A_i - \bar{A})}{\sqrt{\sum(p_i - \bar{P})^2(A_i - \bar{A})^2}} \quad -1 < R < 1 \quad (3)$$

که در آن: p_i : مقادیر پیش‌بینی شده، \bar{P} : میانگین مقادیر پیش‌بینی شده، A_i : مقادیر واقعی و \bar{A} : میانگین مقادیر واقعی می‌باشد. توسط ضریب همبستگی ضریب دیگری تعریف می‌شود که ضریب تبیین^۴ (R^2) نامیده می‌شود و این ضریب در حقیقت نشان دهنده این است که خط برآش تا چه حد روی نقاط نمونه قرار دارند. یک شاخص کمی مناسب دیگر که می‌توان از آن در برآورد میزان دقت مدل استفاده کرد، میانگین مربعات خطأ^۵ (MSE) می‌باشد که دقت مدل را بر اساس تفاضل بین مقادیر واقعی و مقادیر پیش‌بینی شده ارزیابی می‌کند. مقدار MSE بر اساس رابطه (۴) بدست می‌آید.

$$MSE = \frac{1}{n} \sum (P_i - A_i)^2 \quad (4)$$

در این تحقیق برای تقویت عملکرد شبکه‌های عصبی تمرکز اصلی بر روی افزایش تعداد داده‌های لازم برای آموزش شبکه-های عصبی بود. چرا که اگر در هنگام آموزش شبکه از داده‌های مختلفی استفاده شود، باعث می‌شود که شبکه محدوده وسیعی از داده‌ها را تجربه^۶ کرده و در نتیجه میزان اعتماد به عملکرد شبکه افزایش یابد.

به منظور رسیدن به مدل‌های دقیق‌تر و همچنین مدل‌هایی که از نظر زمانی نیز عملکرد مناسب‌تری بر اساس ویژگی‌های رنگی داشته باشند از شبکه‌های عصبی پرسپترون چند لایه با الگوریتم آموزشی پس انتشار خطای استفاده گردید.

برای طراحی مدل شبکه عصبی پرسپترون چند لایه، به منظور جداسازی و دسته‌بندی کلاس‌های تصویر به دو دسته، داده‌های آموزشی^۱ و داده‌های آزمون^۲ مورد نیاز می‌باشد، ۷۰٪ از کل داده‌ها برای آموزش و ۳۰٪ برای آزمون مدل در نظر گرفته شد. لازم

¹ Over training

² Epoch

³ Regression

⁴ Coefficient of Determination

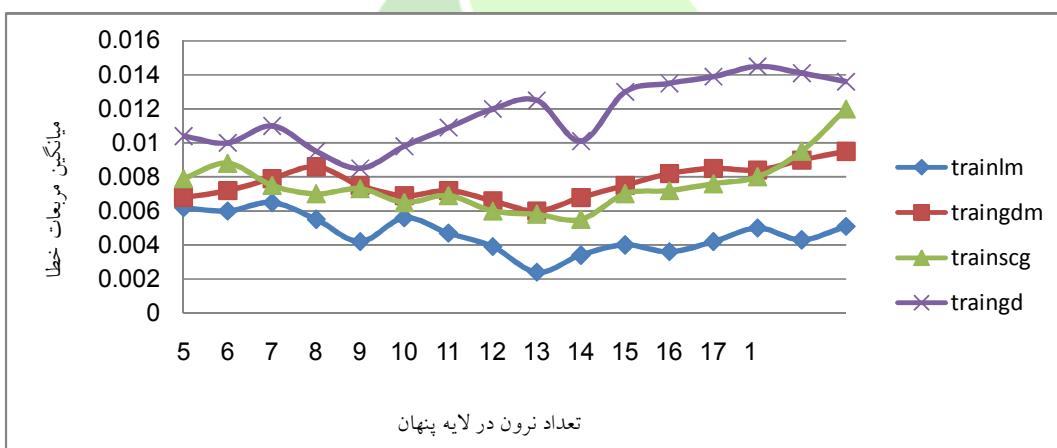
⁵ Mean Squared Error

⁶ Experience

به ذکر است که برخی از محققین از قبیل ناح و همکاران (۲۰۰۶) روش دیگری را برای آموزش و آزمون شبکه عصبی در نظر گرفتند. به اینصورت که در یک مزرعه داده های آموزش شبکه استخراج شده و پس از طراحی و ساخت مدل شبکه عصبی برای آزمون آن از داده های جدید که از مزرعه دیگر برداشت نموده استفاده کردند. این مسئله ممکن است باعث بروز برخی از خطاهای (شرایط مختلف خاک و نور) در شبکه عصبی گردد که در طراحی شبکه در نظر گرفته نشده است.

نتایج و بحث

تأثیر افزایش نرون های لایه پنهان بر میانگین مربعات خطای شبکه در الگوریتم های آموزشی در شکل ۲ دیده می شود. افزایش تعداد نرون های لایه پنهان به بیش از مقدار معینی، باعث افزایش خطای شبکه می شود. دلیل این امر این است که لایه های پنهان به طور سری با هم قرار دارند. در نتیجه برداش نرون های آنها با یکدیگر ترکیب می شوند. این امر موجب می شود با افزایش تعداد نرون های لایه های پنهان، حالت غیر خطی در شبکه عصبی پرسپترون چند لایه افزایش یافته و در نتیجه نرخ همگرایی این شبکه عصبی کاهش یابد.

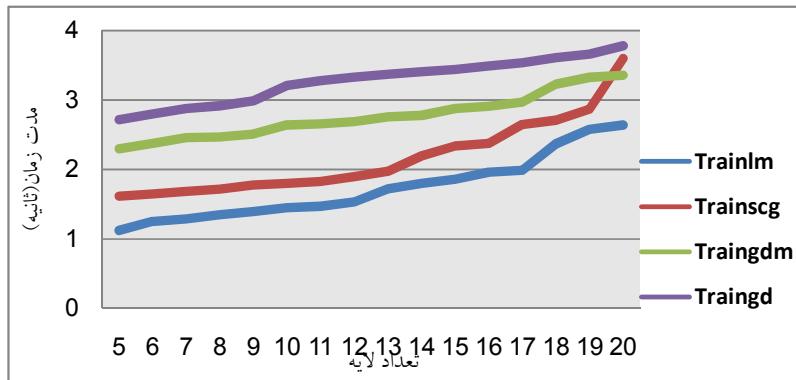


شکل ۲- تأثیر افزایش و کاهش لایه های پنهان بر میانگین مربعات خطای شبکه

همانطور که از نمودار شکل ۳ مشاهده می شود با افزایش تعداد نرون های لایه های پنهان در الگوریتم های آموزشی ذکر شده مدت زمان پردازش افزایش می یابد، نتایج این آزمایش نشان داد که مدل trainlm در مجموع به عنوان بهترین الگوریتم آموزش شبکه انتخاب گردید. تعداد بهینه نرون های لایه پنهان در استفاده از الگوریتم های آموزشی traingdm, traingd, trainscg و trainlm به ترتیب ۹، ۱۳، ۱۴ و ۱۳ عدد و میانگین مربعات خطای آن ها به ترتیب ۰/۰۰۸۵، ۰/۰۰۰۶، ۰/۰۰۵۵ و ۰/۰۰۲۴ بدست آمد.

¹ Training Data

² Test Data



شکل ۳: نمودار نتایج حاصل از تغییر تعداد نرون ها و زمان پردازش شبکه

در این تحقیق به منظور دستیابی به تابع انتقال مناسب از تابع سیگموئیدی و تائزانت هیپربولیک در لایه مخفی استفاده گردید.

نتایج حاصل از این تحقیق، منطبق بر نتایج محققینی نظری (فاست ۱۹۹۴، هایکینز ۱۹۹۴ و منهاج ۱۳۸۴) می باشد و تابع

سیگموئیدی نسبت به تائزانت هیپربولیک دقت مناسبتری دارد. جدول ۱ مقایسه این دو تابع انتقال را در یک شبکه پرسپترون چند

لایه قبل از رسیدن به ساختار بهینه در آن را با دو معیار خوبی تبیین (R^2) و ریشه خطای میانگین مربعات (RMSE) نشان

می دهد.

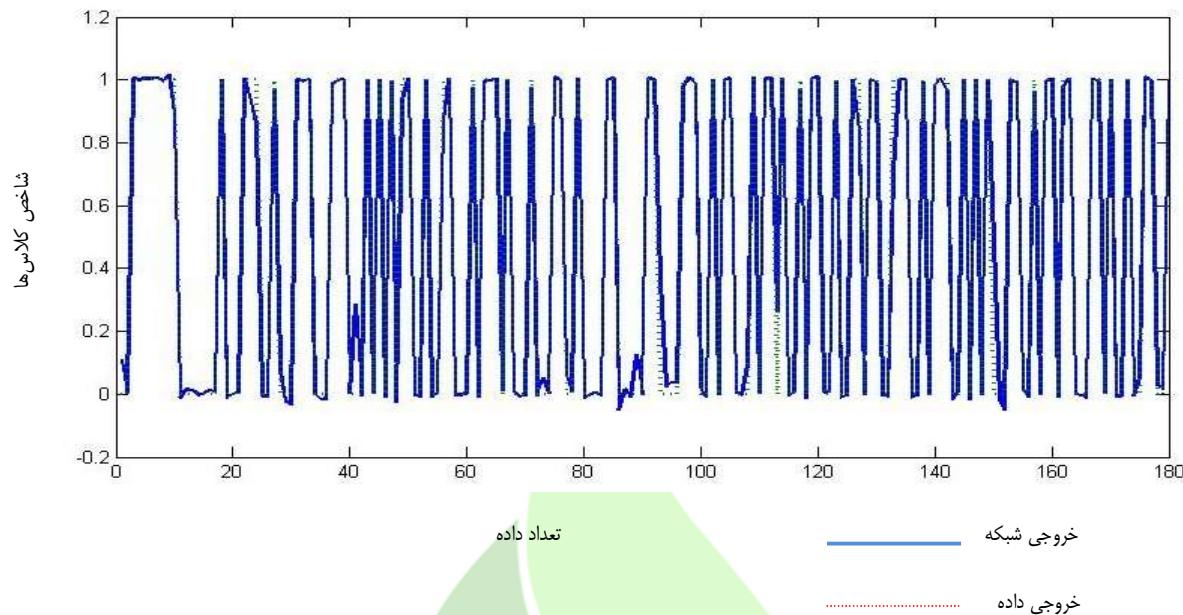
جدول ۱- مقایسه توابع انتقال در شبکه پرسپترون

تابع انتقال	R^2	RMSE
تائزانت هیپربولیک	۰/۸۳۳	۰/۱۲۴
سیگموئید	۰/۸۹۱	۰/۱۱۳

نتایج پیش بینی شبکه پرسپترون چند لایه برای دسته بندی و طبقه بندی داده ها در مرحله آزمون مدل در الگوریتم های آموزشی

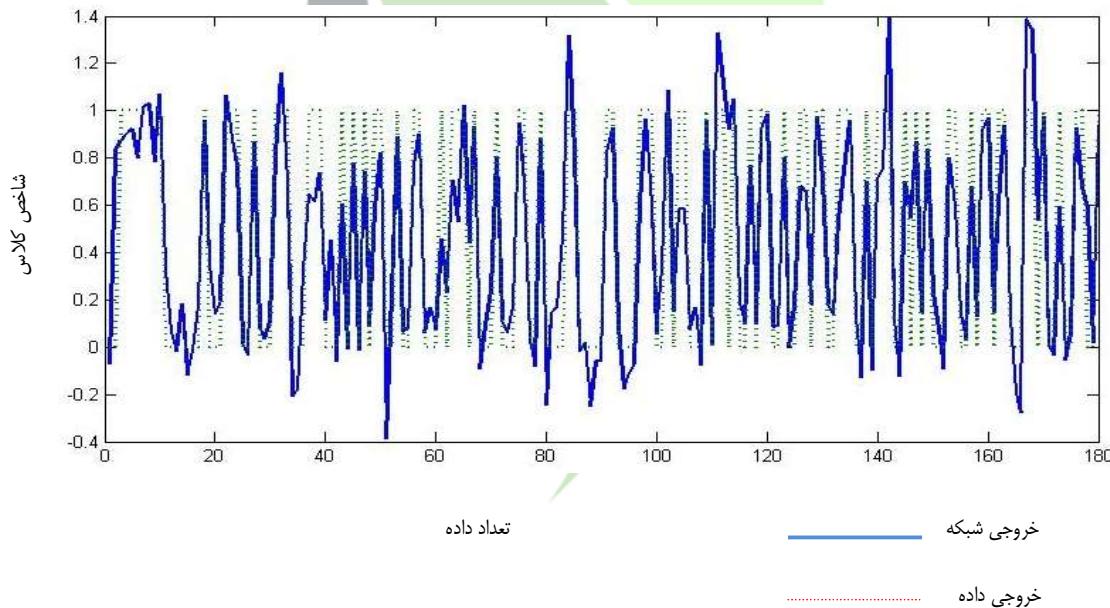
در شکل های ۴ و ۵ بدست آمده است.

¹ Root Mean Squared Error



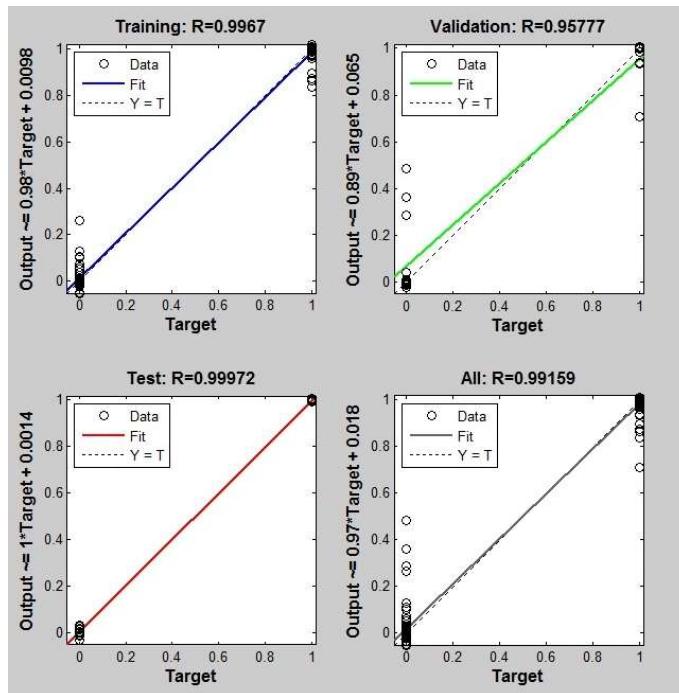
شکل ۴ - مقایسه نتایج مرحله آزمون مدل شبکه پرسپترون چند لایه برای داده های اندازه گیری شده

و پیش بینی الگوریتم آموزشی Trainlm



شکل ۵ - مقایسه نتایج مرحله آزمون مدل شبکه پرسپترون چند لایه برای داده های اندازه گیری شده

و پیش بینی الگوریتم آموزشی Traingd



شکل ۶- نتایج مراحل آموزش، ارزیابی، آزمون ضرایب همبستگی شبکه پرسپترون چند لایه

برای داده های پیش بینی شده با ۱۳ نرون در لایه مخفی

به منظور مقایسه مدل های ایجاد شده و انتخاب بهترین شبکه با بهترین پیش بینی، پارامترهای ضرایب همبستگی، ضرایب تبیین و میانگین مربعات خطأ در مراحل آموزش و آزمون شبکه های ایجاد شده مورد مقایسه قرار گرفت. به منظور بهینه سازی تعداد نرون ها، تعداد لایه های مخفی، نتایج بررسی ها و آنالیز ساختارهای مختلف شبکه عصبی پرسپترون چند لایه نشان داد که شبکه با یک لایه مخفی و تعداد ۱۳ نرون در لایه مخفی آن به دقت مورد نظر می رسد.

نتیجه گیری

از شبکه عصبی پرسپترون چند لایه با الگوریتم یادگیری پس انتشار خطأ به عنوان یکی از ابزارهای هوش مصنوعی برای تشخیص و جداسازی کلاس های تصویر استفاده شد که ورودی شبکه، میانگین مولفه های اصلی رنگ (R, G, B) و پیکسل های تصاویر بود و خروجی شبکه عدد یک (۱) به عنوان خوشه انگور قرمز و عدد صفر (۰) به عنوان غیر انگور قرمز (برگ، آسمان، شاخه و تنہ) در نظر گرفته شد که در نهایت بعد از آزمون و خطای الگوریتم یادگیری و تعداد نرون های شبکه عصبی این نتیجه حاصل شد که با تعداد ۱۳ نرون در لایه مخفی و یک لایه مخفی و الگوریتم یادگیری از نوع Trainlm وتابع انتقال سیگموئیدی، شبکه عصبی با ۹۹ درصد قادر به تشخیص و جداسازی کلاس های تصویر می باشد.

جدول ۲- نتایج بررسی ها و آنالیز ساختارهای مختلف شبکه عصبی پرسپترون چند لایه

نوع شبکه	تعداد لایه مخفی	تعداد نرون در لایه مخفی	آلگوریتم	تابع انتقال لایه مخفی	تابع انتقال لایه خروجی
پرسپترون چند لایه	۱	۱۳	LM	سیگموئیدی	خطی

منابع

- ۱- مارتین تی‌هاگان، هاوارد بی‌دیموث، مارک بیل، ۱۳۸۸، طراحی شبکه‌های عصبی، ترجمه، مصطفی کیا، انتشارات کیان رایانه سیز، تهران.
- ۲- منهاج، م. ۱۳۸۴، مبانی شبکه‌های عصبی مصنوعی (هوش محاسباتی). جلد ۱. انتشارات دانشگاه صنعتی امیرکبیر.
3. Zhao-yan, L. Fang, C.2005. Identification of rice seed varieties using neural network. Journal of Zhejiang University Science, 6.
4. Mery, D. and Pedreschi, F. (2005). Segmentation of colour food images using a robust algorithm . Journal of Food Engineering. 66: 353-360.
5. Tafazzoli, A. Hekmati, J. Firoze, P. 1995. Grape. Shiraz University Publishers
6. Galbaniati, L. 1990. Machine vision and digital image processing fundamentals. Prentice-Hall International Edition.
7. Este , V.F. Angel, D.N., Fernando, M., Arno, F. 2009. A Computer Vision System for Visual Grape Grading in Wine Cellars. In proceeding of: Computer Vision Systems, 7th International Conference on Computer Vision Systems, ICVS 2009, Liège, Belgium, October 13-15, 2009, Proceedings.
8. FAO. 2011. FAOSTAT database. <http://faostat.fao.org/faostat/>. Retrieved 12 October 2011
9. Guye , D.E. and X. Yang. 2000. Use of genetic neural networks and spectral imag for defect detection on cherries. Computers and Electronics in Agricultur . (In press)
10. Chen, Y. R., K. Chao and M. S. Kim. 2002. Machine vision technology for agriculture applications. Computers and electronics in agricultur , 36: 173-191.
11. Ebrahimi, E., Mollazade, K., Arefi, A., An Expert System for Classification of Potato Tubers using Image Processing and Artificial Neural Networks.
12. Zand, M. 2012. Greenhouse Cucumber Image Processing by Neural Network to use in the Cucumber Harvest Robot. A Thesis submitted to Islamic Azad University Takestan Branch for the degree of Master of Science.
13. Majidi, B.H. 2009. Design of intelligent vision system for robot picking apples. A Thesis submitted to Urmia University for the degree of Master of Science.

Red grape cluster detection using image processing and neural networks to be used in robot
grape harvest

Akbar Nazari Chamaki^{1*} Davood Mohammad Zamani² Parviz Ahmadi Moghaddam³ and
Jalaleddin Ghezavati⁴

- 1- MSc Student, Agricultural Machinery Department, Islamic Azad University of Takestan.
akyrred@gmail.com
- 2- Assistant Professor, Agricultural Machinery Department, Islamic Azad University of Takestan.
- 3- Assistant Professor, Agricultural Machinery Department, University of Urmie.
- 4- Young Researchers and Elite Club, Bonab Branch, Islamic Azad University, Bonab, Iran

Abstract

In this paper an automatic classification system based on machine vision and artificial neural networks based on color and its components, was developed. About 300 digital images of grape orchards of Orumieh city in different light conditions in the early hours of the afternoon were cloudy and sunny. Multi-layer Perceptron neural network with error back propagation learning algorithm as a tool for the detection and isolation of artificial intelligence class image was used. Network input, the average components of color (R, G and B) pixel images and the output of the network, the number one (1) as a cluster of red grapes and zero (0) as a non-Grape (leaves, sky, branches and trunks) were considered, After trial and error in the neural network learning algorithm and the number of neurons were found 13 neurons in the hidden layer by using a learning algorithm of hidden layer and sigmoid transfer function Trainlm, Neural network with 98% able to identify and isolate the class picture. The results of image analysis indicated high accuracy in segmenting the regions of the image.

Keywords: red grapes, image processing, machine vision, artificial intelligence