

## برآورد محاسباتی واحدهای رنگی $L^*a^*b^*$ از RGB با کمک پردازش تصاویر دیجیتالی

سامان آبدانان مهدی‌زاده<sup>۱\*</sup>، سمیه امرایی<sup>۲</sup>

تاریخ دریافت: ۱۳۹۳/۱۲/۲۴

تاریخ پذیرش: ۱۳۹۴/۰۳/۰۹

### چکیده

رنگ اولین ویژگی کیفیت مواد غذایی است که توسط مصرف‌کنندگان مورد بررسی قرار می‌گیرد. اندازه‌گیری رنگ مواد غذایی به‌عنوان یک شاخص غیرمستقیم در اندازه‌گیری دیگر ویژگی‌های کیفیتی مانند عطر و طعم و محتویات رنگدانه به دلیل سرعت و سادگی در اندازه‌گیری، و همچنین ارتباط با سایر خواص فیزیکی محصولات غذایی مورد استفاده قرار می‌گیرد. در میان فضاها رنگی مختلف، عموماً در اندازه‌گیری رنگ مواد غذایی، از فضای رنگی  $L^*a^*b^*$  با توجه به توزیع یکنواخت و نزدیکی بسیار زیاد به ادراک انسان استفاده می‌شود. بطور کلی رنگ‌سنج‌های تجاری هنگام اندازه‌گیری رنگ، سطح کوچکی از محصول را پوشش می‌دهند. در مقابل دوربین‌های دیجیتال اطلاعات پیکسلی را در اختیار کاربر قرار می‌دهند؛ این پژوهش یک راه‌حل محاسباتی به‌منظور استخراج واحدهای  $L^*a^*b^*$  از اطلاعات پیکسلی تصاویر RGB دیجیتال را ارائه می‌دهد. در این مطالعه به‌منظور تبدیل واحدهای RGB به  $L^*a^*b^*$  از چهار مدل: خطی، درجه دوم، شبکه عصبی مصنوعی (ANN) و رگرسیون بردار پشتیبانی (SVR) استفاده گردید. در ارزیابی مدل‌ها، رگرسیون بردار پشتیبانی و مدل شبکه عصبی به ترتیب با خطای  $0.08$  و  $0.27$  بهترین عملکرد را از خود نشان دادند. با توجه به مدل‌های شکل گرفته، ارتباط خوبی بین رنگ اندازه‌گیری و برآورد شده تشکیل شده بود. بنابراین، بر اساس نتایج بدست آمده از بینایی ماشین، روش توصیه شده در این پژوهش برای تبدیل دقیق رنگ یک محصول غذایی از روی اطلاعات پیکسلی یک دوربین دیجیتال به  $L^*a^*b^*$  مناسب می‌باشد.

واژه‌های کلیدی: رنگ، RGB،  $L^*a^*b^*$ ، ANN، SVR

### مقدمه

استفاده از ابزار اندازه‌گیری بسیار مورد توجه می‌باشد. از جمله دستگاه‌های رنگ‌سنج متداول می‌توان به مینولتا<sup>۳</sup>، هانتربل<sup>۴</sup> و دکترا لنگ<sup>۵</sup> اشاره کرد. بطور معمول، رنگ در ابزارهای اندازه‌گیری محصولات غذایی به‌صورت  $L^*a^*b^*$  (روشنایی) ( $L^*$ )، قرمزی ( $a^*$ ) و زردی ( $b^*$ ) ارزیابی می‌گردد. این فضای رنگی یک استاندارد بین‌المللی برای اندازه‌گیری رنگ است، که توسط کمیسیون بین‌المللی (CIE) در سال ۱۹۷۶ به تصویب رسید (Mancini *et al.*, 2005). دامنه تغییرات  $L^*$  ۰ تا ۱۰۰ و  $a^*$  و  $b^*$  در محدوده ۱۲۰- تا ۱۲۰ می‌باشد (Yam *et al.*, 2004). فضای رنگی  $L^*a^*b^*$  دارای توزیع یکنواخت می‌باشد، یعنی فاصله اقلیدسی بین دو رنگ مختلف، مطابق با فاصله رنگ ادراک شده توسط چشم انسان است (Pathare *et al.*, 2013). با این حال، معمولاً ابزار مورد استفاده برای اندازه‌گیری رنگ محدودیت پوشش سطوح کوچک را دارند. در این ابزار اگر محل نمونه به دقت انتخاب نگردد تکرارپذیری اندازه‌گیری‌ها کاهش می‌یابد. از طرف دیگر در مواد ناهمگن (مانند اکثر مواد غذایی) اندازه-

برای مصرف‌کنندگان محصولات غذایی، تازگی به‌عنوان مهم-ترین عامل خرید و انتخاب محسوب می‌گردد. رنگ از جمله ویژگی‌هایی است که دارای ارتباطی نزدیک با تازگی است (Maguire, 1994). تعیین رنگ می‌تواند توسط بازدید بصری (انسان) و یا با استفاده از یک ابزار اندازه‌گیری رنگ انجام پذیرد. اگر چه بازرسی انسان حتی در حضور تغییرات نور روشی قدرتمند محسوب می‌گردد، اما تعیین رنگ در این حالت، فردی و از یک ناظر به ناظر دیگر بسیار متغیر است. از این رو به‌منظور انجام تجزیه و تحلیل عینی‌تر رنگ، استانداردهای رنگ اغلب به‌عنوان منابع مرجع استفاده می‌شود. از نقاط ضعف بررسی توسط ناظر می‌توان به کندی و نیاز به آموزش‌های تخصصی و پیچیده ناظران اشاره کرد (Trusell *et al.*, 2005). بنا به دلایل اشاره شده به منظور تعیین علمی و بدون نظر رنگ،

۱ و ۲- به ترتیب استادیار و دانشجوی کارشناسی ارشد گروه مکانیک بیوسیستم

دانشگاه کشاورزی و منابع طبیعی رامین خوزستان

(\*) - نویسنده مسئول: (Email: s.abdanan@Ramin.ac.ir)

DOI: 10.22067/iffstrj.v1395i0.45345

یک جدول رنگ حاوی چندین نمونه با  $L^*a^*b^*$  شناخته شده اندازه-گیری و برای کالیبراسیون اجمالی مورد استفاده قرار گرفته شد. با این حال، جزئیات مدل‌های استفاده شده در مقاله (Hardeberg *et al.*, 1996) داده نشده و پوشش احتمالی رنگ در نمودار در نظر گرفته نشده بود. در پژوهش Leon و همکاران (۲۰۰۶) جداول رنگی ۳۲ عدد بود و از جداول رنگی مشابه استفاده نشده بود. بعلاوه آن‌ها داده‌های بدست آمده را ابتدا به فضای XYZ منتقل می‌کردند سپس به فضای  $L^*a^*b^*$  که این مساله خود نیز محاسباتی و زمان‌بر می‌باشد. در پژوهش حاضر یک روش عمومی ارائه شده که قابلیت پیاده‌سازی در هر سیستم بینایی ماشین را دارد. این مطالعه چهار مدل انتقال RGB به  $L^*a^*b^*$  استفاده کرده است: خطی، درجه دوم، رگرسیون بردار پشتیبان<sup>۱</sup> و شبکه عصبی. در این مقاله اطلاعات مربوط به هر مدل و عملکرد آنها ارائه می‌گردد. هدف از این پژوهش پیدا کردن یک مدل برای بدست آوردن  $L^*a^*b^*$  و برآورد پارامترهای آن از واحدهای رنگی RGB است که مستقیماً RGB را به  $L^*a^*b^*$  تبدیل کند.

## مواد و روش‌ها

### اخذ تصاویر و کالیبراسیون

تصاویر مورد استفاده در این پژوهش با دوربین دیجیتال (Samsung, SM-N9005, Korea) با ۱۳ مگا پیکسل رزولوشن، که بصورت عمودی در فاصله ۶۰ سانتی‌متر از نمونه‌ها قرار داشت اخذ گردیدند. زاویه بین محور لنز و منابع نور در حدود ۴۵ درجه و فلاش دوربین در حالت خاموش قرار داده شد. به منظور تامین نور در سیستم ۴ لامپ نور طبیعی روز ۱۵۰ W استفاده گردید. لامپ‌ها و دوربین همانطور که در شکل (۱) نشان داده شده است در یک جعبه چوبی که دیوارهای داخلی آن برای به حداقل رساندن نور پس زمینه سیاه نقاشی شده بودند قرار گرفتند. وضوح تصاویر اخذ شده (۱۷۰۷×۱۲۸۰) پیکسل بود که به منظور استخراج پارامترهای رنگی به رایانه منتقل گردیدند.

به منظور کالیبره کردن سیستم بینایی ماشین، از ۴۲ صفحه رنگی استفاده گردید. هر صفحه رنگی به ۲۴ ناحیه تقسیم گردید که بعد از اخذ تصاویر به وسیله دوربین، در هر منطقه ارزش رنگ  $L^*a^*b^*$  با استفاده از رنگ‌سنج مینولتا (Minolta Chromameter CR- Japan, Osaka, 400) اندازه‌گیری گردید. بنابراین، ۱۰۰۸ اندازه‌گیری برای واحدهای RGB (متوسط مقادیر برای هر صفحه رنگی در هر ۲۴ ناحیه) به همراه  $L^*a^*b^*$  مربوط به هر ناحیه ثبت گردید.

گیری قابل اعتمادی را از خود نشان نمی‌دهند. بعلاوه هزینه بالای دستگاه‌های رنگ‌سنج نیز شایان ذکر است. از این رو به منظور انجام ارزیابی دقیق ویژگی‌های رنگی محصولات کشاورزی و غذایی، دانستن ارزش رنگ هر پیکسل در سطح آن حائز اهمیت می‌باشد. با این حال، در حال حاضر رنگ‌سنج‌های تجاری در دسترس تنها بیش از چند سانتی‌متر مربع قادر به اندازه‌گیری رنگ محصول نمی‌باشند (Wu *et al.*, 2013).

پیشرفت‌های سریع سخت‌افزار و نرم‌افزار برای اخذ تصاویر دیجیتال و پردازش آن‌ها از یک طرف و کاهش قابل توجه هزینه تجهیزات در طول سال‌های اخیر این تکنولوژی را قابل دسترس و مقرون به صرفه ساخته است. از این رو با توجه به معایب شمرده شده برای رنگ‌سنج‌ها استفاده از روش بینایی ماشین به عنوان یک روش ساده و جایگزین، مورد توجه پژوهشگران متعددی بوده است. این روش دارای توانایی تجزیه و تحلیل هر پیکسل در تمام سطوح مواد غذایی را دارد که این ویژگی یک مزیت عمده نسبت به یک رنگ-سنج معمولی محسوب می‌گردد. رنگ بسیاری از محصولات کشاورزی و غذایی با استفاده از روش‌های بینایی ماشین اندازه‌گیری شده است. از آن جمله می‌توان به ارزیابی رنگ آب پرتقال (Fernandez-Vazquez *et al.*, 2011)، ارزیابی رنگ پوشش گندم و مقایسه آن با روش طیف‌سنجی (Zapotocny *et al.*, 2010)، بررسی رنگ چیپس سیب‌زمینی (Pedreschi *et al.*, 2011)، ارزیابی رنگ اسپاگتی (ناصحی، ۱۳۹۲)، مطالعه تغییرات رنگ در سیب در خلال انبارمانی (Lang *et al.*, 2012) اشاره کرد. در پژوهش‌های یاد شده ابتدا تصاویر در فضای رنگی RGB اخذ می‌شدند و سپس با استفاده از روش‌های محاسباتی و ماتریس انتقال با پارامترهای ثابت به واحدهای  $L^*a^*b^*$  تبدیل شده‌اند. مشکل عمده استفاده از ماتریس انتقال با پارامترهای ثابت این است که فضای رنگی RGB غیرمطلق است یعنی، اندازه‌گیری رنگ در این فضا به عوامل خارجی مانند حساسیت سنسور دوربین، روشنایی، و غیره وابسته است (Ilie & Paschos, 2001; Welch, 2005) و همکاران (۲۰۰۵) گزارش کردند که اکثر دوربین‌های یکسان دارای پاسخ مشابهی نمی‌باشند. این بدین معنی است، که تبدیل RGB به  $L^*a^*b^*$  نمی‌تواند بطور مستقیم با استفاده از یک فرمول استاندارد انجام شود. در نتیجه هدف از این پژوهش به دست آوردن دقیق واحدهای دستگاه-مستقل<sup>۱</sup>  $L^*a^*b^*$  رنگ از دستگاه-وابسته<sup>۲</sup> RGB اخذ شده توسط یک دوربین دیجیتال رنگی است. در روش مشابهی Hardeberg و همکاران (۱۹۹۶) و Leon و همکاران (۲۰۰۶) به توسعه روشی به منظور تبدیل فضای RGB به  $L^*a^*b^*$  پرداخته‌اند. در روش آن‌ها

1 Device-Independent

2 Device-Dependent

آزمون استفاده شدند.

**مدل خطی و درجه دوم**

این دو مدل ساده‌ترین روش‌های انتقال از RGB به  $L^*a^*b^*$  هستند که متغیرهایشان به صورت زیر تعریف می‌شوند (رابطه (۱)) مربوط به مدل خطی و رابطه (۲) مربوط به مدل درجه دوم (Stoderstrom *et al.*, 1989):

$$\begin{bmatrix} \hat{L}^* \\ \hat{a}^* \\ \hat{b}^* \end{bmatrix} = \begin{bmatrix} P_{11} & P_{12} & P_{13} & P_{14} \\ P_{21} & P_{22} & P_{23} & P_{24} \\ P_{31} & P_{32} & P_{33} & P_{34} \end{bmatrix} \begin{bmatrix} R \\ G \\ B \\ 1 \end{bmatrix} \quad (۱)$$


ماتریس ورودی با N اندازه‌گیری برای واحدهای RGB مربوط به مدل خطی و درجه دوم به ترتیب به صورت روابط (۳) و (۴) نمایش داده می‌شود:

$$\begin{bmatrix} \hat{L}^* \\ \hat{a}^* \\ \hat{b}^* \end{bmatrix} = \begin{bmatrix} P_{11} & P_{12} & P_{13} & P_{14} & P_{15} & P_{16} & P_{17} & P_{18} & P_{19} & P_{1,10} \\ P_{21} & P_{22} & P_{23} & P_{24} & P_{25} & P_{26} & P_{27} & P_{28} & P_{29} & P_{2,10} \\ P_{31} & P_{32} & P_{33} & P_{34} & P_{35} & P_{36} & P_{37} & P_{38} & P_{39} & P_{3,10} \end{bmatrix} \begin{bmatrix} R \\ G \\ B \\ RG \\ RB \\ GB \\ R^2 \\ G^2 \\ B^2 \\ 1 \end{bmatrix} \quad (۲)$$

$$X = \begin{bmatrix} R_1 & G_1 & B_1 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ R_N & G_N & B_N & 1 \end{bmatrix} \quad (۳)$$

$$X = \begin{bmatrix} R_1 & G_1 & B_1 & R_1G_1 & R_1B_1 & G_1B_1 & R_1^2 & G_1^2 & B_1^2 & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ R_N & G_N & B_N & R_NG_N & R_NB_N & G_NB_N & R_N^2 & G_N^2 & B_N^2 & 1 \end{bmatrix} \quad (۴)$$

در نتیجه برآورد  $L^*$  با حداقل رساندن نرم ۱ بین اندازه‌گیری و برآورد  $\|y - \hat{y}\|$  به دست می‌آید. مقدار برآورد توسط رابطه (۶) و (۷)



شکل ۱ - محل قرارگیری دوربین، لامپها و کاغذهای رنگی در جعبه اخذ تصاویر

**توسعه مدل‌های انتقالی از RGB به  $L^*a^*b^*$**

قبل از ساخت مدل‌های خطی، درجه دوم و رگرسیون بردار پشتیبان، ۷۰٪ از نمونه‌ها جهت آموزش و ۳۰٪ باقی‌مانده برای تست در نظر گرفته شدند. برای مدل شبکه عصبی که یک مورد خاص بود ۷۰٪ داده‌ها جهت آموزش، ۱۵٪ ارزش‌گذاری و ۱۵٪ باقی‌مانده برای

و بردار خروجی با N اندازه‌گیری برای  $L^*$  به صورت بردار خروجی (۵) مشخص می‌گردد.

$$y = [L_1^* \dots L_N^*]^T \quad (۵)$$

عدد یک مقدار اولیه است که با سعی و خطا بهینه می‌شود. به‌منظور تعیین بهترین الگوریتم آموزشی، از یک لایه مخفی استفاده شد (Hornick *et al.*, 1989). الگوریتم‌های آموزش مختلفی برای پس انتشار وجود دارد که از میان آن‌ها الگوریتم‌های آموزش با سرعت یادگیری متغیر<sup>۳</sup> (traingda)، لوبنرگ-مارکوارت<sup>۴</sup> (trainlm)، کاهش شیب با مومنتم<sup>۵</sup> (traingdm)، پس انتشار ارتجاعی<sup>۶</sup> (trainrp) و شیب توام مقیاس شده<sup>۷</sup> (trainscg) که در مسائل تخمین تابع کارایی بهتری از خود نشان داده و در این پژوهش مورد استفاده و ارزیابی قرار گرفتند (Lolas & Olatunbosun, 2008; Tripathy & Kumar, 2009; Craninx *et al.*, 2008). همچنین از تابع انتقال تانژانت سیگموئید در لایه میانی و تابع خطی در لایه خروجی استفاده گردید. مقدار خطای متوسط آموزش برای شبکه تابع پرسپترون چندلایه با الگوریتم پس انتشار خطا و با توپولوژی‌های مختلف مورد بررسی قرار گرفت. بنابراین الگوریتم مذکور انتخاب و نسبت به بهینه‌سازی آن اقدام شد.

### رگرسیون بردار پشتیبانی

توسعه پایه‌های روش‌های ماشین بردار پشتیبانی<sup>۸</sup> توسط واپنیک در سال ۱۹۹۸ آغاز و به‌طور گسترده به دلیل ویژگی‌های بسیار جذاب و عملکرد تجربی نوید بخش مورد استفاده قرار گرفتند (Vapnik, 1998). ماشین‌های بردار پشتیبانی ابتدا برای حل مسائل طبقه‌بندی توسعه یافتند (Abdanan Mehdizadeh *et al.*, 2014a)؛ سپس در مسائل رگرسیون به‌صورت گسترده استفاده شدند (Alonso *et al.*, 2013).

بیان ریاضی رگرسیون بردار پشتیبانی (SVR) با مجموع داده‌ها شروع می‌شود:

$$S = \{(x_1, y_1), \dots, (x_n, y_n)\} \quad (6)$$

که در  $(x_i, y_i)$ ،  $x_i \in R^d$  و  $y_i \in R$  هر  $Y_i$  مقدار مطلوب خروجی برای بردار ورودی  $X_i$  است. مدل رگرسیون از این الگوها آموزش دیده و برای پیش‌بینی مقدار مطلوب هدف از بردار ورودی-های نادیده استفاده می‌شود. در میان انواع مختلف ماشین بردار پشتیبانی، SVR- $\epsilon$  بیشتر مورد استفاده است (Vapnik, 1998). هدف پیدا کردن تابع  $f(x)$  است که حداکثر انحرافات  $\epsilon$  از داده‌های واقعی  $Y_i$  برای همه داده‌های آموزشی داشته باشد. به عبارت دیگر، تا زمانی که آنها در گروه غیرحساس به  $\epsilon$  ( $\epsilon$ -tube) هستند، به

تعریف می‌شود (Stoderstrom *et al.*, 1989):

$$\hat{y} = x\theta \quad (6)$$

$$\theta = [X^T X]^{-1} X^T y \quad (7)$$

مزیت این مدل این است که مستقیم است و راه حل آن با تکرار به دست نمی‌آید.

### مدل شبکه عصبی

متداول‌ترین نوع شبکه‌های عصبی مصنوعی، عبارتند از پیش-خورد، بازخوردی و رقابتی. در این پژوهش از شبکه‌ی عصبی پیش-خورد استفاده شده‌است. این نوع شبکه‌ی عصبی عمدتاً برای تقریب تابع و طبقه‌بندی الگوها استفاده می‌شود. شبکه‌ی پرسپترون چند لایه<sup>۱</sup>، رایج‌ترین شبکه‌ی پیش‌خورد می‌باشد. این شبکه شامل یک لایه‌ی ورودی، یک یا چند لایه پنهان و یک لایه‌ی خروجی است. برای آموزش این شبکه، از الگوریتم یادگیری پس انتشار<sup>۲</sup> استفاده شد که مراحل آموزش به کمک این الگوریتم عبارتست از (Jam & Fanelli, 2000; Khanna, 1990) (الف)- اختصاص ماتریس وزن تصادفی به هر یک از اتصالات (ب)- انتخاب بردار ورودی و بردار خروجی متناسب با آن (ج)- محاسبه‌ی خروجی نرون در هر لایه و در نتیجه محاسبه‌ی خروجی نرون‌ها در لایه‌ی خروجی (د)- بهنگام‌سازی وزن‌ها به روش پس انتشار خطا (ه)- ارزیابی عملکرد شبکه‌ی آموزش دیده به کمک جذر میانگین مربعات خطا (RMSE) و سرانجام برگشت به قسمت ج یا پایان آموزش.

برای محاسبه واحدهای  $L^*a^*b^*$ ، آموزش و ارزیابی شبکه‌های عصبی مصنوعی از ۳ واحد RGB استفاده شد. تحت شرایط بیان شده در بخش قبل، شبکه‌ی عصبی مصنوعی با ۳ نرون لایه ورودی (B و G و R) و ۳ نرون در لایه‌ی خروجی ( $L^*$ ،  $a^*$  و  $b^*$ ) طراحی شد. شکل (۲) توپولوژی شبکه عصبی مورد استفاده را نشان می‌دهد که در آن پارامترهای ورودی و خروجی آزمایش نشان داده شده است. در این تحقیق از نرم‌افزار MatLab R2013a استفاده شد.

شبکه عصبی طراحی شده دارای ۲ لایه با ۳ نرون در لایه میانی است. به‌منظور انتخاب تعداد نرون در لایه میانی روش‌های ابتکاری متفاوتی وجود دارد که یک روش آن استفاده از تعداد ورودی و خروجی و رابطه (۸) می‌باشد (Abdanan Mehdizadeh *et al.*, 2014).

$$n = \sqrt{\text{inputs} + \text{outputs}} \quad (8)$$

که در این رابطه  $n$  تعداد نرون‌ها در لایه میانی است. البته این

3 Variable Learning Rate  
4 Lovenberg Marquardt  
5 Gradient Descent with Momentum  
6 Resilient backpropagation  
7 Scaled conjugate gradient  
8 Support Vector Machines

1 Multilayer Perceptron  
2 Back Propagation

خطاها اهمیتی داده نمی‌شود (شکل ۳).

در این معادلات،  $C$  پارامتری است که پیچیدگی مدل و خطاهای آموزشی را موازنه می‌کند،  $\xi_i$  و  $\xi_i^*$  به ترتیب متغیرهای بی‌اثر برای مقدار هدف تا بیش و کمتر از  $\varepsilon$  هستند. تابع زیان  $\xi - \varepsilon$  به صورت رابطه (۱۰) تعریف می‌گردد:

$$|\xi|_\varepsilon = \begin{cases} 0 & |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & |\xi| > \varepsilon \end{cases} \quad (10)$$

در نظر داشته باشید که:  $\phi : R^d \rightarrow F$

می‌تواند یک تابع غیر خطی از فضای ورودی  $R^d$  به فضای ویژگی  $f$  باشد. در نتیجه ابرصفحه رگرسیون به صورت رابطه (۱۱) قابل تعریف می‌باشد


$$f(x) = \langle w, \phi(x) \rangle + b \quad (11)$$

$$\frac{1}{2} \langle w, w \rangle + c \sum_{i=1}^n (\xi_i + \xi_i^*),$$


$$\left( \langle w, \phi(x_i) \rangle + b \right) - y_i \leq \varepsilon + \xi_i, \quad (9)$$

$$y_i - \left( \langle w, \phi(x_i) \rangle + b \right) \leq \varepsilon + \xi_i^*,$$

$$\xi_i, \xi_i^* \geq 0, i = 1, \dots, n,$$



شکل ۲- توپولوژی شبکه عصبی مورد استفاده



شکل ۳- تفسیر هندسی  $\varepsilon$ -tube و تابع اتلاف  $\varepsilon$  غیر حساس SVR خطی (Alonso et al., 2013)

به جای فضای ویژگی چند بعدی<sup>۳</sup> است. در این پژوهش از تابع شعاعی پایه<sup>۴</sup> (RBF) یکی از تابع کرنل‌هایی است که بطور گسترده در مسائل خطی و غیرخطی استفاده شده است و به صورت رابطه (۱۲) تعریف می‌شود، استفاده گردید (آبدانان مهدی‌زاده، ۱۳۹۳).

که در آن  $W$  بردار وزن ورودی است، و  $b$  افسست<sup>۱</sup> است. در بسیاری از مسائل ارتباط بین مؤلفه های خروجی و ورودی غیر خطی است؛ در نتیجه به منظور انجام انتقال به توابع کرنل<sup>۲</sup> نیاز می‌باشد. ایده تابع کرنل فراهم نمودن امکان انجام عملیات در فضای ورودی

3 High dimensional  
4 Radial basis function

1 Offset  
2 Kernel

به منظور کارآیی مقایسه گردید.

میانگین خطای نرمال در برآورد هر یک از متغیرهای  $L^*a^*b^*$  به وسیله مقایسه اندازه‌گیری‌های رنگ‌سنج با برآوردهای مدل  $(\hat{L}_i^*, \hat{a}_i^*, \hat{b}_i^*)$  با استفاده از روابط ۱۳، ۱۴ و ۱۵ برای روش‌های مختلف محاسبه گردید.

$$e_L = \frac{1}{N} \sum_{i=1}^N \frac{|L_i^* - \hat{L}_i^*|}{\Delta L} \quad (13)$$

$$e_a = \frac{1}{N} \sum_{i=1}^N \frac{|a_i^* - \hat{a}_i^*|}{\Delta a} \quad (14)$$

$$e_b = \frac{1}{N} \sum_{i=1}^N \frac{|b_i^* - \hat{b}_i^*|}{\Delta L} \quad (15)$$

خطاها با توجه به طیف وسیعی از هر یک از مقیاس‌ها نرمالیزه و میانگین خطای محاسبه شده برای هر روش در جدول (۲) گزارش شده است

مدل نشان می‌دهد که رگرسیون بردار پشتیبان و شبکه عصبی بهترین عملکرد در محاسبه  $L^*a^*b^*$  دارند و با خطا کل ۰/۸۸ و ۲/۳۷ به ترتیب عملکرد خوبی را برای آزمایش‌های بعدی تضمین می‌کند. برای بهترین مدل‌ها (رگرسیون بردار پشتیبان و شبکه عصبی)، نمودار مقادیر واقعی و برآورد شده ترسیم گردید (شکل ۵). مطابق شکل ۵ همبستگی بالایی میان مقادیر واقعی  $L^*a^*b^*$  با برآورد شده  $(\hat{L}_i^*, \hat{a}_i^*, \hat{b}_i^*)$  وجود دارد که این مساله حاکی از قابلیت بالای روش بینایی ماشین در تبدیل پارامترهای رنگی دوربین دیجیتال (RGB) به  $L^*a^*b^*$  است

به منظور نشان دادن قابلیت روش پیشنهادی، رنگ یک پوست پرتقال و درون میوه کیوی با استفاده از هر دو روش رنگ‌سنجی هانتر لب و روش بینایی ماشین اندازه‌گیری شد. اندازه‌گیری با دستگاه رنگ‌سنجی با میانگین ۶ اندازه‌گیری (در ۶ مکان مختلف در سطح پوست پرتقال و درون میوه کیوی) بدست آمد. در حالی که اندازه‌گیری با استفاده از بینایی ماشین با میانگین تمام پیکسل‌ها از تصویر سطح تخمین زده شد. نتایج بدست آمده در شکل (۶) آورده شده است به منظور تعیین وجود ارتباط معنی‌دار میان پارامترهای محاسبه شده به روش بینایی ماشین و اندازه‌گیری شده با دستگاه رنگ‌سنجی برای دو میوه کیوی و پرتقال ضرایب همبستگی میان این دو روش محاسبه گردید (جدول ۳ و ۴).

مطابق ضرایب همبستگی بدست آمده در جداول ۳ و ۴ میان اعداد محاسبه شده با هر دو روش بینایی ماشین (ANN و SVR) برای هر دو میوه پرتقال و کیوی و اعداد اندازه‌گیری شده با دستگاه رنگ‌سنجی در سطح احتمال ۵٪ ارتباط معنی‌داری وجود دارد که این مساله حاکی از دقت روش پیشنهادی است. در پژوهشی Leon و همکاران (۲۰۰۶) مدل‌های مختلف برای تبدیل ارزش قرمز، سبز و

$$K_R(x, \hat{x}) = e^{(-\gamma \|x - \hat{x}\|^2)}, \quad \gamma > 0 \quad (12)$$

که در آن C پارامتر عرض کرنل است.

برای رسیدن به عملکرد مطلوب SVR، در کرنل RBF دو پارامتر  $\gamma$  (رابطه ۱۲) و C (رابطه ۹) نیاز به تنظیم دارد. در پژوهش حاضر مقدار خطای RMSE برای بهترین عملکرد محاسبه و مقادیر ذکر شده با استفاده از روش بهینه‌سازی محدب<sup>۱</sup> از بازه  $[10^{-3} \ 10^3]$  به ترتیب ۰/۵ و ۴۰۰ برای  $\gamma$  و C بدست آمدند.

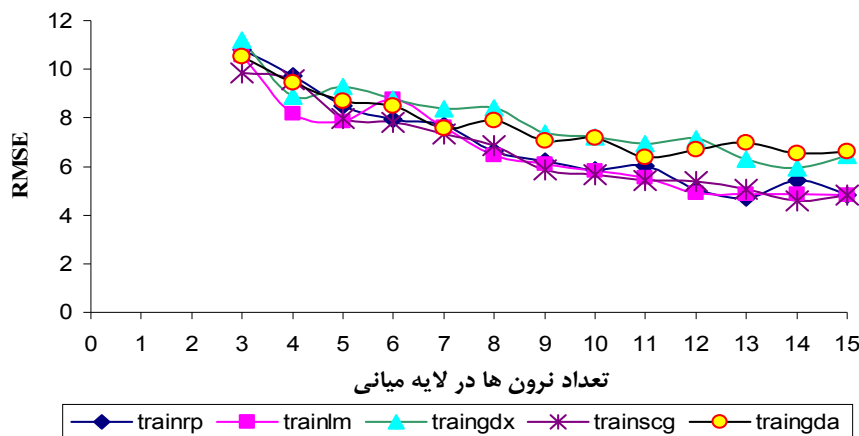
## نتایج و بحث

در ابتدا با توجه به اینکه روش شبکه عصبی یک روش محاسباتی است و نیاز به بهینه‌سازی تعداد نرون‌ها در لایه میانی دارد تعداد نرون‌های لایه میانی از ۳ تا ۱۵ نرون تغییر داده شد. تعداد بهینه نرون‌ها در لایه میانی برای هر الگوریتم آموزش با توجه به مقدار RMSE محاسبه گردید (شکل ۴). شایان ذکر است که با توجه به اینکه الگوریتم آموزش traindm دارای نوسانات زیاد و دقت کمتری در برآورد واحدهای  $L^*a^*b^*$  داشت به آن در شکل (۴) اشاره نشد نتایج آموزش نشان داد، کم‌ترین مقدار میانگین مربعات خطا برای شبکه پرسپترون با قاعده یادگیری پس‌انتشار ارتجاعی (trainrp) با ۱۳ نرون در لایه میانی بود. به منظور تسهیل مقایسه بهترین حالت الگوریتم‌های آموزش نتایج الگوریتم‌های مختلف آموزش در جدول (۱) لیست گردید.

مطابق جدول ۱ دو الگوریتم با قاعده یادگیری پس‌انتشار ارتجاعی (trainrp) با ضریب همبستگی ۰/۹۵۵ و مجذور میانگین مربعات خطا ۴/۸۲ و لونبرگ-مارکوارت (trainlm) با ضریب همبستگی ۰/۹۵۴ و مجذور میانگین مربعات خطا ۴/۸۳ برآورد بهترین واحدهای  $L^*a^*b^*$  داشتند Craninx و همکاران (۲۰۰۸) در پژوهشی از الگوریتم‌های مختلف آموزش در شبکه عصبی به منظور پیشگویی گوی تخمیر در شکمبه گاو شیری استفاده نمودند. آنها دریافتند که الگوریتم آموزشی لونبرگ-مارکوارت با ۱۴ نرون در لایه میانی بهترین پیشگویی گوی تخمیر را داشت. Lolos و همکاران (۲۰۰۸) در پژوهشی دیگر که به منظور پیشگویی قابلیت اطمینان خودروها از شبکه عصبی استفاده گردید از میان الگوریتم‌های آموزشی مختلف، پس‌انتشار ارتجاعی در مقایسه با الگوریتم‌های دیگر جواب یکنواخت-تری از خود ارائه داد. در این پژوهش دومین، بهترین الگوریتم آموزشی از نظر یکنواختی در جواب‌ها الگوریتم لونبرگ-مارکوارت گزارش گردید. در نتیجه از میان الگوریتم‌های مختلف یادگیری پس-انتشار ارتجاعی با ۱۳ نرون در لایه میانی انتخاب و با روش‌های دیگر

توسط ناظر صورت پذیرفت. رنگ بدست آمده در روش بینایی ماشین بسیار نزدیک به متوسط رنگ واقعی فیله ماهی آزاد اقیانوس اطلس تعیین شده توسط ناظر بود. در حالی که اندازه‌گیری صورت پذیرفته با استفاده از رنگ‌سنج متمایل به رنگ ارغوانی برای هر ۳ پارامتر رنگی  $L^*$ ،  $a^*$  و  $b^*$  مشاهده گردید. با توجه به مقادیر بدست آمده روش پیشنهادی قابلیت تبدیل موفق واحدهای رنگی دستگاه-وابسته (RGB) به دستگاه-مستقل ( $L^*a^*b^*$ ) را دارا می‌باشد. البته شایان ذکر است که روش پیشنهادی نسبی می‌باشد و در صورتی که شرایط (نور پردازی و دوربین) تغییر کنند توابع انتقال می‌بایست مجدد بدست بیایند.

آبی از تصاویر دیجیتال به  $CIEL^*a^*b$  فضای رنگی مقایسه کردند. آنها مجموعه‌ای از ۳۲ نمودار رنگی استفاده کردند و مشاهده کردند که زمانی که یک مدل درجه دوم و یک شبکه عصبی مورد استفاده قرار گرفت رگرسیون بین مختصات رنگ  $CIEL^*a^*b$  بدست آمده از تصاویر دیجیتال و رنگ‌سنج با ضریب تشخیص ( $R^2$ ) بیشتر از ۰/۹۹ مرتبط می‌باشد. Yagiz و همکاران (۲۰۰۹) در پژوهشی دیگر روش رنگ‌سنجی با دستگاه مینولتا و بینایی ماشین در اندازه‌گیری رنگ ماهی آزاد تابش دیده با امواج UV با دوزهای مختلف را با یکدیگر مقایسه کردند. اعداد بدست آمده در روش بینایی ماشین برای  $L^*$ ،  $a^*$  و  $b^*$  در مقایسه با رنگ‌سنج مینولتا به صورت معنی‌داری بالاتر بودند. سپس به منظور تعیین رنگ‌های واقعی، ارزیابی بصری بر روی نمونه‌ها



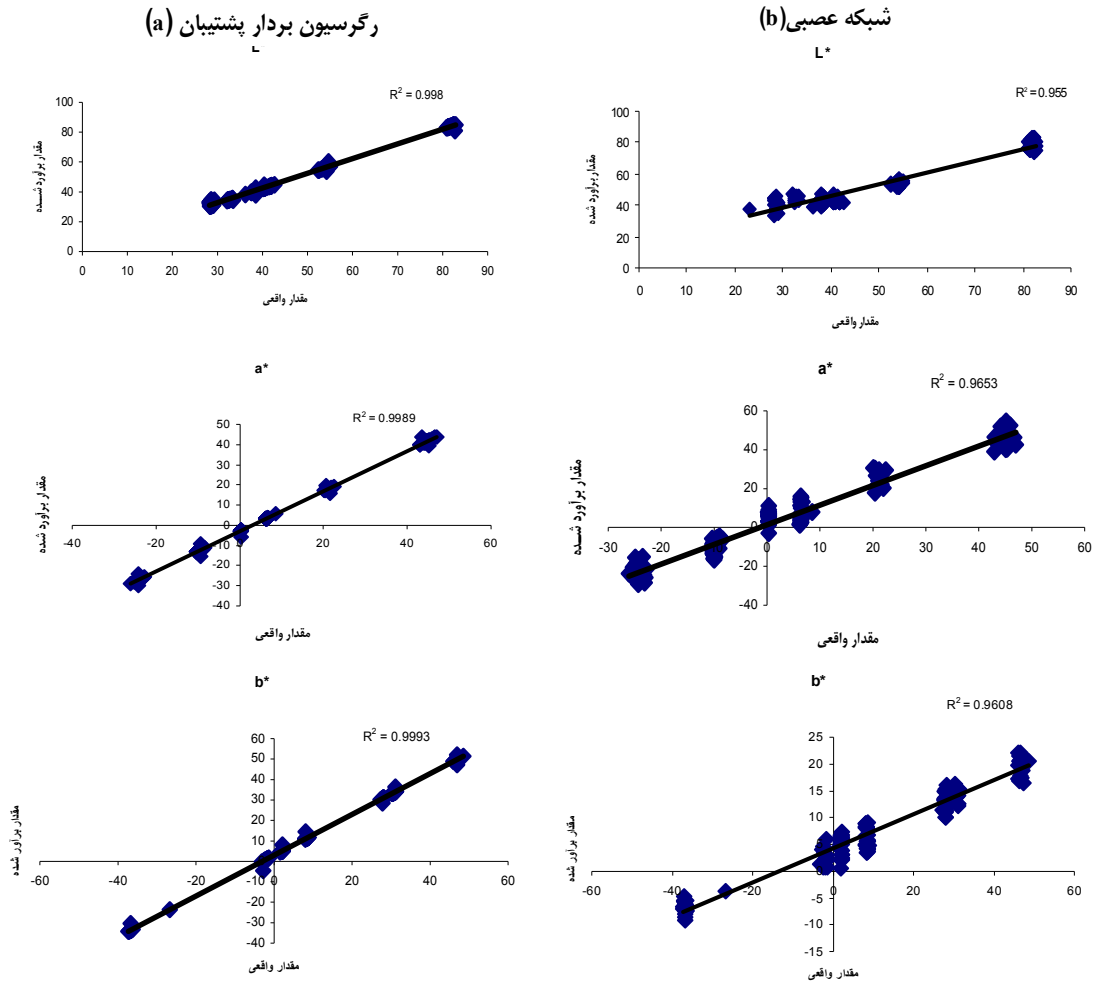
شکل ۴- مقدار خطای پیشگویی با قواعد یادگیری مختلف بر اساس تعداد نرون‌های مختلف در لایه میانی

جدول ۱- مشخصات مربوط به شبکه‌های ایجادشده

الگوریتم آموزشی	تعداد نرون‌ها در لایه مخفی	ضریب همبستگی مجموعه آموزش	مجدور میانگین مربعات خطا (RMSE)
traingdm	۱۱	۰/۴۲۳	۴۲/۷۵
traingdx	۱۴	۰/۹۲۲	۵/۹۵
traingda	۱۰	۰/۹۱۹	۶/۳۷
trainlm	۱۳	۰/۹۵۴	۴/۸۳
trainscg	۱۴	۰/۹۴۱	۵/۰۷
trainrp	۱۳	۰/۹۵۵	۴/۸۲


جدول ۲- خطاها در محاسبه  $L^*a^*b^*$  در مراحل مختلف

مدل	آموزش (%)	آزمون (%)	کل (%)
خطی	۱۵/۷۱	۱۵/۸۶	۱۵/۸۵
درجه دوم	۲۰/۱۱	۱۹/۹۳	۱۹/۹۲
شبکه عصبی	۲/۵۴	۲/۴۹	۲/۳۷
رگرسیون بردار پشتیبان	۱/۲۱	۰/۹۵	۰/۸۸




شکل ۵- مقادیر تخمین زده شده  $L^*a^*b^*$  با روش‌های رگرسیون بردار پشتیبان (ستون (a)) و شبکه عصبی (ستون (b))

روش اندازه‌گیری	$L^*$	$a^*$	$b^*$
رنگ‌سنج	۵۸/۹۸	۲۸/۳۲	۳۵/۴۹
بینایی ماشین (SVR)	۶۱/۲۰	۲۷/۳۰	۳۵/۳۸
بینایی ماشین (ANN)	۶۰/۱۸	۳۰/۱۹	۳۰/۶۰



روش اندازه‌گیری	$L^*$	$a^*$	$b^*$
رنگ‌سنج	۱۳/۷۴	۱۶/۵	۱۲/۶۰
بینایی ماشین (SVR)	۴۱/۲۹	۷/۱۳	۱۴/۵۳
بینایی ماشین (ANN)	۴۳/۹۱	۳/۷۳	۹/۲۸



شکل ۶- مقادیر تخمین زده شده  $L^*a^*b^*$  با روش‌های رگرسیون بردار پشتیبان و عصبی شبکه برای سطح پوست پرتقال و درون میوه کیوی



جدول ۳- آنالیز همبستگی میان پارامترهای محاسبه شده به روش بینایی ماشین و اندازه‌گیری شده بوسیله دستگاه رنگ‌سنج برای میوه پرتقال

رنگ‌سنج	بینایی ماشین (SVR)	بینایی ماشین (ANN)
رنگ‌سنج	۰/۹۶۳*	۰/۹۵۹*
بینایی ماشین (SVR)	۱	۰/۹۵۰*
بینایی ماشین (ANN)	۰/۹۵۹*	۱

\* در سطح احتمال ۵٪ و معنی‌دار است.

جدول ۴- آنالیز همبستگی میان پارامترهای محاسبه شده به روش بینایی ماشین و اندازه‌گیری شده بوسیله دستگاه رنگ‌سنج برای دو میوه کیوی

رنگ‌سنج	بینایی ماشین (SVR)	بینایی ماشین (ANN)
رنگ‌سنج	۰/۹۵۱*	۰/۸۹۳*
بینایی ماشین (SVR)	۱	۰/۷۰۹ <sup>n.s</sup>
بینایی ماشین (ANN)	۰/۷۰۹ <sup>n.s</sup>	۱

در سطح احتمال ۵٪ و معنی‌دار است.

n.s معنی‌دار نیست.

## نتیجه‌گیری

شبکه عصبی مصنوعی (ANN) و رگرسیون بردار پشتیبانی (SVR) به منظور استخراج واحدهای  $L^*a^*b^*$  از اطلاعات پیکسلی تصاویر RGB دیجیتال ارائه شد. با توجه به ارزیابی مدل‌ها، رگرسیون بردار پشتیبانی و مدل شبکه عصبی به ترتیب با خطای ۰/۸۸ و ۲/۳۷ بهترین عملکرد را از خود نشان دادند. بنابراین، بر اساس نتایج بدست آمده از بینایی ماشین، از روش توصیه شده در این پژوهش برای تبدیل اطلاعات پیکسلی یک دوربین دیجیتال (RGB) به  $L^*a^*b^*$  می‌توان به خوبی بهره جست.

رنگ از جمله ویژگی‌هایی است که دارای ارتباطی نزدیکی با تازگی است. از میان فضای رنگی متفاوت  $L^*a^*b^*$  دارای با توجه به داشتن توزیع یکنواخت، مطابق با فاصله رنگ ادراک شده توسط چشم انسان می‌باشد. اما دستگاه‌های رنگ‌سنج تجاری بطور کلی هنگام اندازه‌گیری رنگ، سطح کوچکی از محصول را پوشش می‌دهند. در مقابل دوربین‌های دیجیتال اطلاعات پیکسلی را در اختیار کاربر قرار می‌دهند. در این پژوهش از روش‌های محاسباتی خطی، درجه دوم،

## منابع

- آبدانان مهدیزاده، س.، ۱۳۹۵. تشخیص ترک در پوسته تخم‌مرغ با استفاده از PCA و SVM. مجله علوم و صنایع غذایی ایران، ۵۶(۱۳)، ۱۴۳-۱۵۳.
- ناصری، ب.، ۱۳۹۲، بررسی روش‌های مختلف ارزیابی رنگ در اسپاگتی، نشریه پژوهش‌های صنایع غذایی، (۱)، ۲۳(۱)، ۴۷-۵۷.
- Abdanan Mehdizadeh, S., Minaei, S., Hancock, N. H. & Karimi Torshizi M. A., 2014. An intelligent system for egg quality classification based on visible-infrared transmittance spectroscopy. *Information Processing in Agriculture*, 1, 105-114.
- Abdanan Mehdizadeh, S., Sandell, G., Golpour, A. & Karimi Torshizi M. A., 2014. Early Determination of Pharaoh Quail Sex after Hatching Using Machine Vision. *Bulletin of Environment, Pharmacology and Life Sciences*, 1, 105-114.
- Alonso, J., Castanon, A. R., & Bahamonde, A., 2013. Support Vector Regression to predict carcass weight in beef cattle in advance of the slaughter. *Computers and Electronics in Agriculture*, 91, 116-120.
- Craninx, M., Fievez, V., Vlaeminck, B., & De Baets, B., 2008. Artificial neural network models of the rumen fermentation pattern in dairy cattle. *Computers and Electronics in Agriculture*, 60(2), 226-238.
- Fernandez-Vazquez, R., Stinco, C. M., Melendez-Martinez, A. J., Heredia, F. J., & Vicario, I. M., 2011. Visual and instrumental evaluation of orange juice color: a consumers' preference study. *Journal of Sensory Studies*, 26, 436-444.
- Hardeberg, J. Y., Schmitt, F., Tastl, I., Brettel, H., & Cretz, J.-P., 1996. In Proceedings of 4th Color Imaging Conference: Color Science, Systems and Applications, Scottsdale, Arizona, Nov, pp. 108-113.
- Hornick, K., Stinchcombe, M., & White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2, 359-366.
- Ilie, A., & Welch, G., 2005. Ensuring color consistency across multiple cameras. In Proceedings of the tenth IEEE international conference on computer vision (ICCV-05), Vol. 2, 17-20 Oct (pp. 1268-1275).
- Jam, L., & Fanelli, A. M., 2000. Recent advances in artificial neural networks design and applications, CRC Press.

- Khanna, T., 1990. Foundations of Neural Networks, Addison-Wesley Publishing Company.
- Lang, C., & Hübert, T., 2012. A color ripeness indicator for apples. *Food and Bioprocess Technology*, 5(8), 3244-3249.
- Leon, K., Mery, D., Pedreschi, F., & Leon, J., 2006. Color measurement in L\*a\* b\* units from RGB digital images. *Food research international*, 39(10), 1084-1091.
- Lolas, S., & Olatunbosun, O. A., 2008. Prediction of vehicle reliability performance using artificial neural networks. *Expert Systems with Applications*, 34(4), 2360-2369.
- Maguire, K., 1994. Perceptions of meat and food: Some implications for health promotion strategies. *British Food Journal*, 96(2), 11-17.
- Mancini, R. A., & Hunt, M. C., 2005. Current research in meat color. *Meat Science*, 71(1), 100-121.
- Mendoza, F., & Aguilera, J. M., 2004. Application of image analysis for classification of ripening bananas. *Journal of Food Science*, 69, 471-477.
- Paschos, G., 2001. Perceptually uniform color spaces for color texture analysis: an empirical evaluation. *IEEE Transactions on Image Processing*, 10(6), pp.932-937.
- Pathare, P. B., Opara, U. L., & Al-Said, F. A. J., 2013. Color measurement and analysis in fresh and processed foods: a review. *Food and Bioprocess Technology*, 6(1), 36-60.
- Pedreschi, F., Mery, D., Bungler, A., & Yanez, V., 2011. Computer vision classification of potato chips by color. *Journal of Food Process Engineering*, 34, 1714-1728.
- Stoderstrom, T., & Stoica, P., 1989. System identification. New York: Prentice-Hall.
- Tripathy, P. P., & Kumar, S., 2009. Neural network approach for food temperature prediction during solar drying. *International Journal of Thermal Sciences*, 48(7), 1452-1459.
- Trusell, H. J., Saber, E., & Vrhel, M., 2005. Color image processing, *IEEE Signal Processing Magazine*, 22(1), 14-22.
- Vapnik, V.N., 1998. Statistical Learning Theory. *Wiley-Interscience*, New York.
- Wu, D., & Sun, D. W., 2013. Color measurements by computer vision for food quality control—A review. *Trends in Food Science & Technology*, 29(1), 5-20.
- Yagiz, Y., Balaban, M. O., Kristinsson, H. G., Welt, B. A., & Marshall, M. R., 2009. Comparison of Minolta colorimeter and machine vision system in measuring colour of irradiated Atlantic salmon. *Journal of the Science of Food and Agriculture*, 89, 728-730.
- Yam, K. L., & Papadakis, S., 2004. A simple digital imaging method for measuring and analyzing color of food surfaces. *Journal of Food Engineering*, 61, 137-142.
- Zapotoczny, P., & Majewska, K., 2010. A comparative analysis of colour measurements of the seed coat and endosperm of wheat kernels performed by various techniques. *International Journal of Food Properties*, 13, 75-89.

## Computational estimation of L\*a\*b\* units from RGB using machine vision

S. Abdanan Mehdizadeh<sup>\*1</sup>, S. Amraee<sup>2</sup>

Received: 2015.03.15

Accepted: 2015.05.30

**Introduction:** Color is the first quality attribute of food evaluated by consumers, and is therefore an important quality component of food which influences consumer's choice and preferences (Maguire, 1994). Color measurement of food products has been used as an indirect measure of other quality attributes such as flavor and contents of pigments because it is simpler, faster and correlates well with other physicochemical properties. Therefore, rapid and objective measurement of food color is required in quality control for the commercial grading of products (Trusell *et al.*, 2005). Among different color spaces, L\*a\*b\* color space is the most practical system used for measuring of color in food due to the uniform distribution of colors in this system as well its high similarity to human perception of color. All of the commercial L\*a\*b\* colorimeters generally measure small, non- representative areas (Pathare *et al.*, 2013) while the RGB digital cameras obtain information in pixels. Therefore, this research establishes a computational solution which allows acquiring of digital images in L\*a\*b\* color units for each pixel from the digital RGB image (Fernandez-Vazquez *et al.*, 2011). In recent years, computer vision has been used to objectively measure the color of different foods since they provide some obvious advantages over a conventional colorimeter, namely, the possibility of analyzing of each pixel of the entire surface of the food, and quantifying surface characteristics and defects (Mendoza & Aguilera, 2004). The color of many foods has been measured using computer vision techniques (Pedreschi *et al.*, 2011; Lang *et al.*, 2012). A computational technique with a combination of a digital camera, image processing software has been used to provide a less expensive and more versatile way to measure the color of many foods than traditional color-measuring instruments. This study used four models to carry out the RGB to L\*a\*b\* transformation: linear, quadratic, support vector regression and neural network. This article presents the details of each model, their performance, and their advantages and disadvantages. The purpose of this work was to find a model (and estimate its parameters) for obtaining L\*a\*b\* color measurements from RGB measurements.

**Materials and Methods:** The images used in this work were taken with the following image acquisition system (Samsung, SM-N9005 color digital camera with 13 Mega pixels of resolution ,Fig.1). The camera was placed vertically at a distance of 60 cm from the samples and the angle between the axis of the lens and the sources of illumination was approximately °45. Illumination was achieved with 4 natural daylight 150 W lights.




Fig. 1. Schematic diagram of image acquisition system.


In order to calibrate the digital color system, the color values of 42 color charts were measured. Each color chart was

1 and 2 Assistant professor and MSc student of Mechanics of Biosystems Engineering , Department, Faculty of Agricultural Engineering and Rural Development, Ramin University of Agriculture and Natural Resources of Khuzestan, Respectively.

(\*Corresponding Author Email: saman.abdanan@gmail.com)

divided into 24 regions. In each region, the  $L^*a^*b^*$  color values were measured using a Minolta colorimeter. Additionally, a RGB digital image was taken of each chart, and the R, G and B color values of the corresponding regions were measured using a Matlab program which computes the mean values for each color value in each region according to the 24 masks. In this study four models for the RGB to  $L^*a^*b^*$  transformation namely: linear, quadratic, artificial neural network (ANN), support vector regression (SVR) have been used.

**Results and discussion:** In the evaluation of the performance of the models, the support vector regression and neural network model stands out with an error of only 0.88 and 2.37, respectively. Leon et al. (2004) investigated some models for the RGB to  $L^*a^*b^*$  conversion. In the evaluation of the performance of the models, the neural network model showed an error of only 0.93%. In another research Yagzi et al. (2009) measured the  $L^*a^*b^*$  values of atlantic salmon fillets subjected to different electron beam doses (0, 1, 1.5, 2 and 3 kGy) using a Minolta CR-200 Chroma Meter and a machine vision system. For both Minolta and machine vision the  $L^*$  value increased and the  $a^*$  and  $b^*$  values decreased with increasing irradiation dose. However, the machine vision system showed significantly higher readings for  $L^*$ ,  $a^*$ ,  $b^*$  values than the Minolta colorimeter. According to the construction of these models, the correlation between measured and predicted color is well established; therefore, based on the promising obtained results from Computer vision, it is possible to find a  $L^*a^*b^*$  color measuring system that is appropriate for an accurate, exacting and detailed characterization of a food item based on a color digital camera. In order to show the capability of the proposed method, the color of an orange was measured using both a Minolta colorimeter and the studied approach. The colorimeter measurement was obtained by averaging 6 measurements in 6 different places of the surface of the orange, whereas the measurement using the digital color image was estimated by averaging all pixels of the surface image. The results are summarized in Fig. 2.



Measurement Method	$L^*$	$a^*$	$b^*$
Minolta colorimeter	58.98	28.32	35.49
Machine Vision (SVR)	61.20	27.30	37.35
Machine Vision (ANN)	60.18	30.19	30.60

Fig. 2. Estimate of  $L^*a^*b^*$  values of an orange

**Key word:** Color, RGB,  $L^*a^*b^*$ , ANN, SVR