

تدوین و ارزیابی مدل‌های عصبی مصنوعی به‌منظور برآورد مقادیر L^* ، a^* و b^* با استفاده از مقادیر R ، G و B تصاویر رنگی به کمک بینایی رایانه‌ای

سجاد کیانی^۱، سعید مینایی^{۲*}

۱. دانشجوی دکتری، گروه مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس

۲. استاد، گروه مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس

(تاریخ دریافت: 95/9/25، تاریخ بازنگری: 95/12/13، تاریخ پذیرش: 95/12/13)

چکیده

با توجه به نیاز استفاده از مقادیر رنگی L^* ، a^* و b^* به همراه دیگر پارامترهای رنگی از جمله مقادیر R ، G و B در کاربردهای کنترل کیفیت رنگی مواد غذایی و کشاورزی، در این پژوهش روشی هوشمند بر پایه سامانه بینایی ماشین، شبکه‌های عصبی مصنوعی MLP و روش آماری چند متغیره PLS برای برآورد از مقادیر L^* ، a^* و b^* از مقادیر R ، G و B تصاویر رنگی نمونه‌های مختلف زعفران تدوین گردید. تصاویر رنگی از 33 نمونه مختلف زعفران (165 تصویر) و از صفحات رنگی استاندارد (150 تصویر) تهیه شدند. به کمک سامانه بینایی ماشین ساخته شده تصاویر نمونه‌ها دریافت و با استفاده از الگوریتم‌های پردازش تصویر، پردازش و ویژگی‌های رنگی R ، G و B آن‌ها استخراج گردید. از سوی دیگر ویژگی‌های L^* ، a^* و b^* نمونه‌ها توسط دستگاه رنگ‌سنج (به روش هانتز لپ) اندازه‌گیری شدند. مقادیر RGB و تبدیلات خطی آن‌ها به‌عنوان ورودی مدل‌ها و مقادیر مرتبط L^* ، a^* و b^* به ترتیب به‌عنوان خروجی و هدف مدل‌ها در نظر گرفته شدند. در نهایت نتایج نشان داد که مدل‌های MLP با دقت بالاتری و ضرایب رگرسیون مناسب‌تری نسبت به مدل‌های PLS مقایر L^* ، a^* و b^* نمونه‌های زعفران را برآورد کردند ($R^2=0/99$) و RMSE به ترتیب برابر با 0/769، 0/953 و 0/785 برای برآورد هر سه ویژگی L^* ، a^* و b^* ، در نهایت می‌توان امکان استفاده از سامانه بینایی ماشین را برای کنترل کیفیت رنگی زعفران بیان کرد.

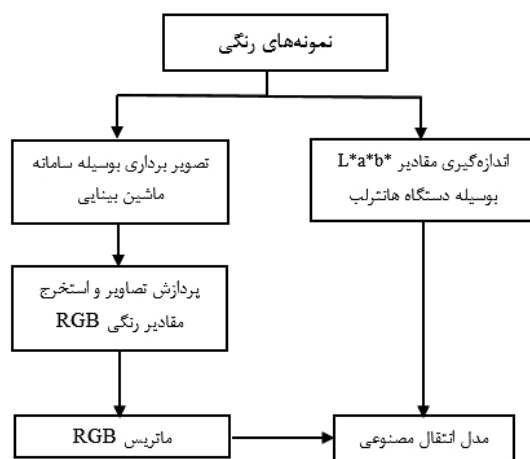
واژه‌های کلیدی: برآورد، پردازش تصاویر، زعفران، $L^*a^*b^*$.

1- مقدمه

است [15] و صحیح به نظر می‌رسد که مجموعه فضاهای رنگی فوق در کاربردهای پردازش تصویر مورد بررسی قرار گیرند. به دلایل تاثیرات نورپردازی و مشخصات دوربین‌های تصویربرداری در کیفیت تصاویر، تبدیلات خطی از فضای RGB به فضای $L^*a^*b^*$ امکان‌پذیر نمی‌باشد [8]. دریافت مقادیر $L^*a^*b^*$ به‌وسیله دستگاه رنگ‌سنج هانتر لب زمان‌بر و پرهزینه می‌باشد و همچنین این دستگاه قابلیت برخط شدن را ندارد. بنابراین در این پژوهش روشی بر مبنای سامانه بینایی ماشین، شبکه‌های عصبی مصنوعی MLP و روش آماری PLS به‌منظور تبدیل مقادیر رنگی از فضای RGB به فضای $L^*a^*b^*$ تدوین و ارزیابی شد.

2- مواد و روش‌ها

در نمودار روند نمای شکل (1) روش انتقالی هوشمند به‌منظور تبدیل فضای رنگی RGB به فضای $L^*a^*b^*$ نشان داده شده است.



شکل (1) نمودار روندنمای تخمین مقادیر $L^*a^*b^*$ با استفاده از مقادیر RGB

2-1- انتخاب نمونه‌ها، تصویربرداری و پردازش تصاویر

تعداد 165 عدد تصویر رنگی از 33 نمونه مختلف زعفران (5 تصویر از هر نمونه زعفران و هر بار تصویر برداری بعد از بهم زدن نمونه) و 150 عدد تصویر رنگی استاندارد به‌منظور دربر داشتن دامنه وسیعی از رنگ‌ها برای این کاربرد خاص انتخاب شدند. تصاویر رنگی با استفاده از سامانه بینایی ماشین موجود و توسعه یافته در پژوهش پیشین دریافت شدند [16]. شکل (2) نشان دهنده سامانه بینایی ماشین توسعه یافته و شکل (3) نمونه‌هایی از تصاویر رنگی را نشان می‌دهد. از تصاویر رنگی را نشان می‌دهد.

سامانه بینایی ماشین¹ شامل دوربین تصویربرداری، سامانه نورپردازی و الگوریتم‌های دریافت و پردازش تصاویر است [1]. با استفاده از الگوریتم‌های پردازش تصاویر، اطلاعات رقمی تصاویر دریافت شده استخراج و برای اندازه‌گیری سریع و غیرمخرب مورد استفاده قرار می‌گیرند. این روش به‌عنوان یک ابزار رنگ‌سنج دیجیتال، کم‌هزینه و چند منظوره در مقابل روش‌های مرسوم مانند طیف‌سنجی و رنگ‌سنجی به‌وسیله دستگاه هانتر لب قابل استفاده می‌باشد. سامانه‌های بینایی ماشین به‌طور گسترده‌ای برای تعیین کیفیت رنگ تعداد مختلفی از مواد غذایی و به‌صورت برخط استفاده شده است. مثال‌های از این سامانه عبارتند از برای ارزیابی کیفیت رنگی موز [2]، گوشت [3]، ماهی [4]، نوشیدنی‌ها [5، 6]، عسل [7]، دانه‌های قهوه [8، 9] و محصولات متفاوت دیگر [10، 11]. رنگ یک ویژگی بسیار مهم است که به‌طور گسترده در ارزیابی مواد غذایی و محصولات کشاورزی استفاده می‌شود و همچنین یک فاکتور کلیدی در بازار پسندی این محصولات می‌باشد [12]. استاندارد بین‌المللی اندازه‌گیری رنگ، $CIE L^*a^*b^*$ ، توسط کمیسیون بین‌المللی d'Eclairage در سال 1986 برای ارزیابی رنگ تصویب شده است. این فضای رنگی مستقل از دستگاه تصویربرداری و شرایط محیطی آن می‌باشد [13]. این فضای رنگی با مختصات (به شرح الف) L^* یا تابناکی، مربوط به درجه تاریکی مواد و با عددی بین 0 (سیاه) تا 100 (سفید) بیان می‌شود، a^* بازه قرمز تا سبز را با عددی بین 120- تا 120 مشخص می‌کند و b^* بازه آبی تا زرد را با عددی بین 120- تا 120 مشخص می‌کند، بیان می‌شود. همچنین در بسیاری از کاربردهای رنگ‌سنجی از فضای رنگی RGB و تبدیلات خطی آن یعنی HSV، YIQ و YCbCr استفاده می‌شود. توضیحات بیش‌تر این فضاهای رنگی در کتاب‌ها و مقالات متعدد از جمله [7، 14] یافت می‌شود. تصاویر رنگی با فرمت RGB و در نتیجه تبدیلات خطی آن به شدت تحت تاثیر پارمترهایی مانند نورپردازی و مشخصات دوربین‌های تصویربرداری قرار دارند [8]. در بسیاری از موارد کنترل کیفیت مواد غذایی و کشاورزی که از ترکیب فضاهای رنگی استفاده کرده‌اند، قدرت تفکیک پذیری فضای رنگی $L^*a^*b^*$ نسبت به فضای RGB موثرتر گزارش شده


پیش پردازش تصاویر دریافت شده نمونه‌های زعفران به روش میانگین‌گیری (10×10) قسمت برش خورده هر تصویر به‌منظور حذف ناهموازی‌های موجود در آن‌ها انجام گرفت و مقادیر RGB تصاویر استخراج گردید. ماتریس مقادیر RGB و تبدیلات خطی آن‌ها یعنی مقادیر YIQ، HSV و YCbCr به‌عنوان 11 ویژگی رنگی در نظر گرفته شدند. کلیه مراحل دریافت، پیش پردازش، پردازش و ذخیره‌سازی مقادیر رنگی با استفاده از نرم افزار متلب انجام گرفت.

2-3- مدل‌های انتقال


برای توسعه مدل‌های انتقال می‌توان از مدل‌های غیرخطی مانند شبکه‌های عصبی مصنوعی و مدل‌های آماری چند متغیره خطی استفاده کرد. از شبکه‌های عصبی مصنوعی چند لایه MLP به‌عنوان مدل غیرخطی و از روش PLS به‌عنوان مدل آماری خطی چند متغیره استفاده شد. مقادیر 11 ویژگی رنگی به‌عنوان مقادیر ورودی مدل‌های شبکه عصبی مصنوعی و مقادیر L^* ، a^* و b^* به‌صورت جداگانه به‌عنوان خروجی مدل‌ها در نظر گرفته شدند. شکل (4) نشان دهنده نمودار گرافیکی مدل MLP توسعه یافته می‌باشد.

2-2- اندازه‌گیری مقادیر $L^*a^*b^*$ نمونه‌ها


مقادیر $L^*a^*b^*$ نمونه‌های مورد نظر در سه تکرار توسط دستگاه رنگ‌سنج هانتر لب (Hunter Lab, color Flex, USA) ($L^*(97)$ ، $a^*(0/25)$ و $b^*(1/78)$) اندازه‌گیری شدند. میانگین مقادیر به‌دست آمده به‌عنوان ویژگی‌های رنگی هر تصویر با



شکل (2) سامانه بینایی ماشین قابل حمل توسعه یافته



شکل (3) تصاویر رنگی دریافت شده، ستون‌های 1 و 2 نمونه‌های تصاویر زعفران و ستون‌های 3 و 4 نمونه‌های تصاویر صفحات رنگی استاندارد



شکل (4) شماتیک مدل‌های عصبی مصنوعی توسعه یافته

روش آماری PLS نیز به‌عنوان یک روش خطی چند متغیره برای برآورد مقادیر L^* ، a^* و b^* با استفاده از مقادیر RGB و همچنین به جهت مقایسه با مدل‌های MLP مورد استفاده قرار گرفت. بدین منظور از این مدل برای محاسبه ضرایب رگرسیون مقادیر 11 ویژگی رنگی در برآورد مقادیر L^* ، a^* و b^* استفاده شد [18]. توضیحات بیشتر در مورد مدل‌های MLP و روش‌های آماری چند متغیره توسط اسکوت و همکاران [19] بیان شده است. مدل‌های MLP با استفاده از نرم افزار متلب و مدل‌های PLS با استفاده از نرم افزار آنسکرملر تدوین شدند.

3- نتایج و بحث

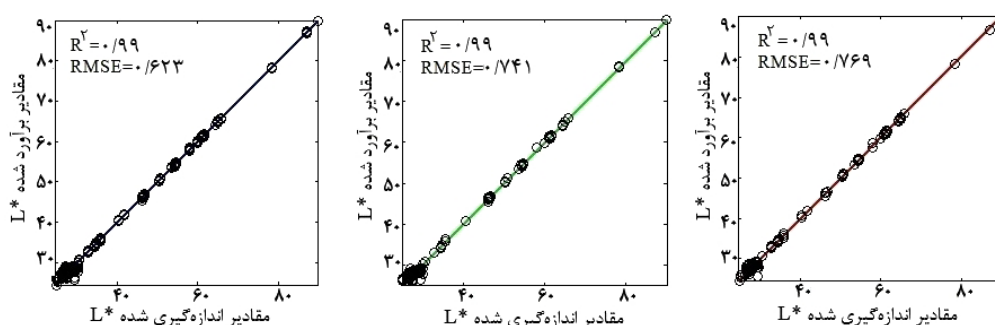
3-1- نتایج مدل‌های شبکه عصبی مصنوعی

در مدل‌های غیرخطی MLP تدوین شده، تعداد نورون‌های لایه میانی از 3 لایه شروع و تا 15 لایه آزمایش‌ها تکرار شدند. بهترین عملکرد (حداقل مقدار RMSE) زمانی به‌دست آمد که 10 نورون در لایه پنهان در نظر گرفته شده بود. ارتباط بین مقادیر اندازه‌گیری شده و پیش‌بینی شده L^* ، a^* و b^* در اشکال (5) تا (7) نشان داده شده است.


مقادیر ضرایب رگرسیون R^2 به‌ترتیب برای کلیه مراحل آموزش،

با استفاده از جعبه افزار شبکه‌های عصبی مصنوعی نرم افزار متلب سه مدل مصنوعی MLP، هر کدام با یک لایه ورودی با 11 نورون و متناسب با مقادیر ورودی، یک لایه مخفی و یک لایه خروجی با یک نورون به ترتیب متناسب با مقادیر L^* ، a^* و b^* ساخته شدند. از الگوریتم پیش فرض آموزش یعنی الگوریتم لونبرگ مارکوات (trainlm) استفاده شد [17]. همچنین ماتریس مقادیر ورودی مدل‌ها (11×315) به‌صورت پیش فرض به سه قسمت 70 درصد برای آموزش، 15 درصد برای ارزیابی و 15 درصد برای تست مدل‌ها تقسیم شدند. روش آزمون و خطا برای تعیین تعداد نورون‌های لایه مخفی و با در نظر گرفتن ریشه حداقل مربعات خطا (RMSE) به‌کار گرفته شد. توابع انتقال تانزانت سیگموئید و خطی به‌ترتیب در لایه میانی و خروجی استفاده شدند. اجرای شبکه 3 مرتبه انجام و مدل‌ها با حداقل مقدار RMSE در نظر گرفته شدند. در نهایت اختلاف مقادیر برآورد شده و مقادیر واقعی اندازه‌گیری شده L^* ، a^* و b^* به‌وسیله معادله (1) به‌عنوان اختلاف رنگ یک نمونه یا ΔE_{ab}^* قابل اندازه‌گیری می‌باشد [15].

$$\Delta E_{ab}^* = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} \quad (1)$$



شکل (5) ارتباط میان مقادیر اندازه‌گیری شده و پیش‌بینی شده L^* (از چپ به‌ترتیب مراحل آموزش، ارزیابی و تست)



شکل (6) ارتباط میان مقادیر اندازه‌گیری شده و پیش‌بینی شده a^* (از چپ به‌ترتیب مراحل آموزش، ارزیابی و تست)

مقادیر برآورد شده توسط مدل های MLP با استفاده از معادله (1) قابل محاسبه می باشد. اختلافات رنگی (ΔE_{ab}^*) به دست آمده از معادله (1) در شکل (9) نشان داده شده است.


کمترین مقدار ΔE_{ab}^* که توسط چشم غیر مسلح قابل تشخیص است برابر با 2/2 می باشد [20]. در این پژوهش مقدار میانگین ΔE_{ab}^* برابر با 1/299 و حداکثر 2/98 به دست آمد. ستون های قرمز رنگ مقادیر ΔE_{ab}^* را نشان می دهند که مقادیر آن ها در محدوده تشخیص چشم مسلح انسان می باشند. در نهایت این نتایج این حقیقت را روشن می کنند که سامانه ماشین بینایی با دقت قابل قبولی توانایی برآورد مقادیر ویژگی های L^* ، a^* و b^* نمونه های زعفران را داشته و همچنین این مقادیر برای کنترل کیفیت رنگی زعفران مناسب هستند.

2-3- نتایج مدل های PLS

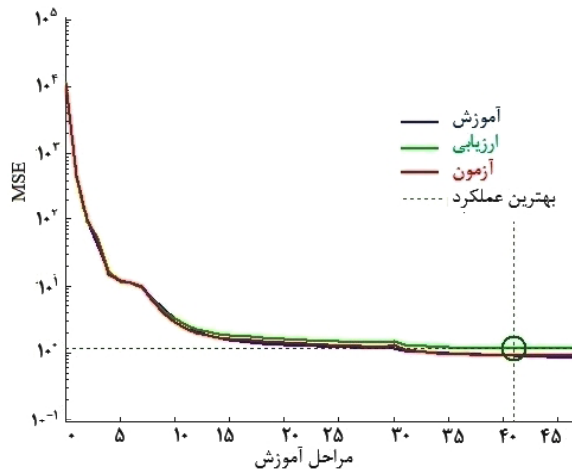
عملکرد مدل های خطی PLS برای برآورد مقادیر L^* ، a^* و b^* به صورت نتایج مقادیر R^2 و RMSE در جدول (1)

ارزیابی و تست 0/99 به دست آمد. همچنین مقادیر RMSE به ترتیب برای مراحل آموزش، ارزیابی و تست 0/741، 0/623 و 0/769 استخراج گردید. به وضوح مشخص است که ارتباط میان مقادیر برآورد شده و اندازه گیری شده L^* ، a^* و b^* از نظر مقادیر R^2 و RMSE در حد قابل قبول می باشد و می توان از مدل های MLP برای استخراج مقادیر L^* ، a^* و b^* با استفاده از مقادیر RGB استفاده کرد. جهت اطمینان از آموزش صحیح مدل های عصبی مصنوعی تدوین شده و اطمینان از بیش آموزش نشدن آن ها نمودار عملکرد آموزش، ارزیابی و آزمایش آن ها را می توان بررسی کرد. بدین صورت که در این نمودارها، در صورتی که نمودار خطی آزمایش به صورت مشابه با نمودار خطی آموزش سیر نزولی را طی کند، مدل آموزش دیده قابل اطمینان خواهد بود. به عنوان نمونه عملکرد آموزش، ارزیابی و آزمایش مدل عصبی توسعه یافته برای برآورد مقادیر a^* در شکل (8) نشان داده شده است.

در توضیحات مدل MLP بیان شد که اختلافات بین مقادیر L^* ، a^* و b^* اندازه گیری شده توسط دستگاه رنگ سنج و



شکل (7) ارتباط میان مقادیر اندازه گیری شده و پیش بینی شده b^* (از چپ به ترتیب مراحل آموزش، ارزیابی و تست)



شکل (8) نمودار عملکرد آموزش، ارزیابی و آزمایش مدل عصبی توسعه یافته برای تخمین مقادیر L^*

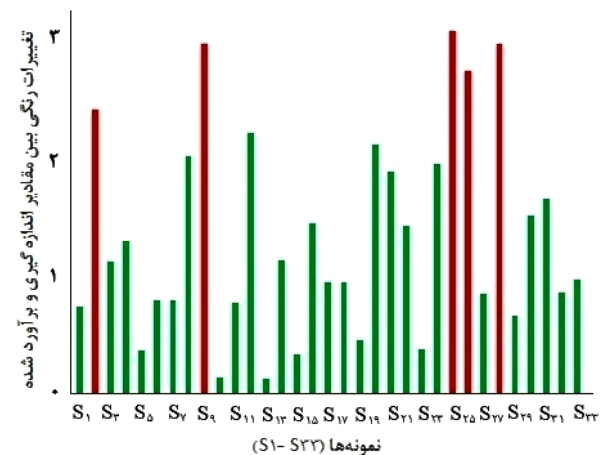
4- نتیجه‌گیری

امروزه با توجه به اهمیت رنگ در کنترل کیفیت مواد غذایی و محصولات کشاورزی از ویژگی‌های مختلف رنگی این محصولات از جمله R، G و B، تبدیلات خطی آن‌ها و همچنین ویژگی‌های L^* ، a^* و b^* استفاده می‌شود. تبدیلات خطی L^* ، a^* و b^* از مقادیر R، G و B امکان‌پذیر نمی‌باشد. اندازه‌گیری مقادیر L^* ، a^* و b^* به وسیله دستگاه رنگ‌سنج هانتر لب زمان‌بر، پرهزینه و همچنین به صورت غیر برخط است. در نتیجه توسعه مدل‌های انتقال برای برآورد برخط مقادیر L^* ، a^* و b^* از مقادیر R، G و B مورد نیاز می‌باشد. در این پژوهش 315 نمونه رنگی انتخاب، تصاویر دریافت، پردازش و ویژگی‌های R، G و B و تبدیلات خطی آن‌ها استخراج گردید. مقادیر L^* ، a^* و b^* نمونه‌ها به وسیله دستگاه رنگ‌سنج هانتر لب اندازه‌گیری و مدل‌های انتقال MLP و PLS توسعه داده شدند. با توجه به نتایج به دست آمده ($R^2 = 0/99$ و RMSE به ترتیب برابر با 0/769، 0/953 و 0/785 برای برآورد هر سه ویژگی L^* ، a^* و b^*) می‌توان نتیجه‌گیری کرد که ترکیب سامانه ماشین بینایی و شبکه‌های عصبی MLP روش مناسبی برای برآورد برخط مقادیر L^* ، a^* و b^* با استفاده از مقادیر R، G و B می‌باشد در صورتی که ترکیب سامانه بینایی ماشین و روش آماری PLS دقت قابل قبولی نداشت (R^2 به ترتیب برابر با 0/86، 0/786 و 0/70 و RMSE به ترتیب برابر با 5/977، 9/166 و 6/73 برای برآورد هر سه ویژگی L^* ، a^* و b^*).

نشان داده شده است. با ملاحظه این نتایج و مقایسه با نتایج مدل‌های MLP مشخص می‌شود که مدل‌های خطی و چند متغیره PLS برای برآورد مقادیر L^* ، a^* و b^* با استفاده از مقادیر رنگی R، G و B توانایی پایین‌تری نسبت به مدل‌های غیرخطی MLP دارند.

معادله (2) بیانگر مدل‌های برآورد PLS برای ضرایب L^* ، a^* و b^* می‌باشد. در این معادله a_1 تا a_{11} ضرایب هر کدام از مقادیر رنگی R، G و B و ترکیبات خطی آن‌ها می‌باشد. جدول (2) نشان دهنده مقادیر این ضرایب می‌باشد.

$$L^*, a^* \text{ or } b^* = a_1(R) + a_2(G) + a_3(B) + a_4(Y) + a_5(I) + a_6(Q) + a_7(Cb) + a_8(Cr) + a_9(H) + a_{10}(S) + a_{11}(V) \quad (2)$$



جدول (1) نتایج مدل‌های PLS برای برآورد مقادیر L^* ، a^* و b^*

مدل	مشخصات رنگی	R^2		RMSE		Bias	
		Cal	Val	Cal	Val	Cal	Val
PLS	L^*	0/873	0/86	5/86	5/977	0/000	-0/0042
	a^*	0/79	0/786	9/93	9/166	0/000	0/325
	b^*	0/71	0/70	6/67	6/73	0/000	-0/014

جدول (2) ضرایب رگرسیون برآورد زده شده به وسیله مدل‌های PLS

مدل	مشخصات رنگی	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8	a_9	a_{10}	a_{11}
PLS	L^*	-23/0	24/0	11/0	-/01	-05/0	-16/0	17/1-	72/0	02/0	00	00/0
	a^*	45/0	27/0-	00/0	12/0	03/0	27/0	62/0	34/0	00/0	02/0-	01/0-
	b^*	-32/0	25/0	27/0	10/0	-/32	-08/0	82/0-	91/0	01/0	01/0	00/0

منابع

- Electrical and Electronics Engineering* - IAENG Special Edition of the, 167-174.
- [10] Sliwinska, M., Wisniewska, P., Dymerski, T., Namiesnik, J & Wardencki. W. (2014). Food Analysis Using Artificial Senses, *J. Agric. Food Chem.*, 62, 1423–1448.
- [11] Chen, Q., Zhang, Z., Pan, W., Ouyang, Q., Li, H., Urmila, K., & Zhao, J. (2015). Recent developments of green analytical techniques in analysis of tea's quality and nutrition. *Trend. Food Sci. Technol.*, 43, 63-82.
- [12] Kiani, S., Minaei, S. (2016a). Potential Application of Machine Vision Technology to Saffron (*Crocus sativus* L) Quality Characterization, *Food Chem.*, 212, 392-394.
- [13] CIE. (1986). *Colorimetry*, second edition. CIE Central Bureau Kegelgasse Publication, Wien, Austria. 27 (15), A-1030.
- [14] Du, C., Sun, D. (2005). Comparison of three methods for classification of pizza topping using different color spaces transformations. *J. Food Eng.*, 68, 277–287.
- [15] Leon, K., Mery, D., Pedreschi, F., Le on, J. (2006). Color measurement in $L^*a^*b^*$ units from RGB digital images. *Food Res. Int.* 39, 1084-1091.
- [16] Kiani, S., Minaei, S., & Ayyari, M. (2016b). A non-destructive intelligent technique for color-based saffron quality characterization using computer vision. 5th International Congress on Medicinal Plants, 18-19 May, 2016, Esfahan, Iran.
- [17] Marquardt, D. (1963). An algorithm for least squares estimation of non-linear parameters, *J. Soc. Indust. Appl. Math.* 11, 431–441.
- [18] Patel, H.K. (2014). *The Electronic Nose: Artificial Olfaction Technology*, Springer.
- [1] Wu, D., Sun, D.W. (2013). Color measurements by computer vision for food quality control-a review. *Food Sci. Technol.* 29 (1), 5-20.
- [2] Mendoza, F., & Aguilera, J.M. (2004). Application of image analysis for classification of ripening bananas. *J. Food Sci.*, 69, 471-477.
- [3] Larrain, R.E., Schaefer, D.M., Reed, J.D. (2008). Use of digital images to estimate CIE color coordinates of beef. *Food Res. Int.*, 41, 380-385.
- [4] 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 color of irradiated Atlantic salmon. *J. Sci. Food Agric.* 89, 728-730.
- [5] Martin, M.L.G.M., Ji, W., Luo, R., Hutchings, J., Heredia, F.J. (2007). Measuring color appearance of red wines. *Food Qual. Prefer.* 18, 862-871.
- [6] 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. *J. Sens. Stud.*, 26, 436-444.
- [7] Shafiee, S., Minaei, S., Moghaddam-Charkari, N., & Barzegar, M. (2014). Honey characterization using computer vision system and artificial neural networks. *Food Chem.*, 159, 143–150.
- [8] Oliveira, E. M, de., Leme, D. S., Barbosa, B. H. G., Rodarte, M. P., Pereira, R. G. F. A. (2016). A computer vision system for coffee beans classification based on computational intelligence techniques. *JFE*, 171, 22-27.
- [9] Sanz-Urbe, J.R., Ramos-Giraldo, P.J., Oliveros-Tascon, C.E. (2008). Algorithm to identify maturation stages of coffee fruits. In: World Congress on Engineering and Computer Science, WCECS '08. *Advances in*

[19] Scott, S.M., James, D., Ali, Z. (2007). Data analysis for electronic nose systems, *Microchim. Acta*, 156, 183–207.

[20] Brainard, D. H. (2003). Color appearance and color difference specification. In S. K. Shevell (Ed.), the science of color, second edition, 191–216. *Amsterdam: Elsevier Science Ltd.*