

## ساخت و توسعه یک سامانه‌ی ماشین بویایی در ترکیب با روش‌های شناسایی الگو برای تشخیص تقلب فرمالین در شیر خام

مجتبی توحیدی<sup>۱</sup>، مهدی قاسمی ورنامخواستی<sup>۱\*</sup>، وحید غفاری نیا<sup>۲</sup>، سید سعید محتسبی<sup>۳</sup> و مجتبی بنیادیان<sup>۴</sup>

۱. دانشجوی دکتری و استادیار، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه شهرکرد.

۲. استادیار، گروه الکترونیک، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان.

۳. استاد گروه مهندسی ماشین‌های کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران.

۴. دانشیار گروه بهداشت مواد غذایی، دانشکده دامپزشکی، دانشگاه شهرکرد

(تاریخ دریافت: ۱۳۹۵/۶/۸ - تاریخ تصویب: ۱۳۹۵/۹/۱)

### چکیده

تقلب در شیر و دیگر محصولات لبنی نه تنها یک تهدید جدی برای سلامت انسان است بلکه زیان‌های اقتصادی متعددی را نیز به دنبال دارد. از جمله تقلبات رایج در شیر خام، استفاده از مواد بازدارنده بار میکروبی است. در این پژوهش، یک سامانه‌ی ماشین بویایی (بینی الکترونیکی) بر پایه هشت حسگر نیمه هادی اکسید فلزی (MOS) ساخته شد و قابلیت آن در تشخیص مقادیر مختلف فرمالین در شیر خام (۰، ۰/۰۵، ۰/۱، ۰/۲ و ۰/۳ درصد) مورد بررسی قرار گرفت. بردار ویژگی‌ها از سیگنال پاسخ حسگرها استخراج و به عنوان ورودی مدل‌های تشخیص الگو استفاده شد. بر اساس نتایج حاصل، آنالیز مؤلفه‌های اصلی با دو مولفه‌ی PC1 و PC2، ۹۳٪ از واریانس داده‌ها را پوشش داد. در مجموعه‌ی حسگری، حسگرهای MQ4، FIS، TGS822 و TGS2620 بالاترین مقادیر ضریب لودینگ و حسگر TGS2602 کمترین مقدار این ضریب را به خود اختصاص دادند. همچنین استفاده از روش تحلیل تفکیک خطی، دقت طبقه‌بندی ۸۰/۱٪ را نشان داد. با کاربرد ماشین بردار پشتیبان با تابع چندجمله‌ای درجه سه، دقت آموزش و اعتبارسنجی طبقه‌بندی به ترتیب ۱۰۰٪ و ۹۰/۹۱٪ به دست آمد. دقت طبقه‌بندی کل نیز با به کارگیری تکنیک شبکه‌های عصبی مصنوعی ۱۰۰٪ به دست آمد.

**واژه‌های کلیدی:** بینی الکترونیکی، حسگرهای نیمه هادی، فرمالین، تحلیل مؤلفه‌های اصلی، شبکه‌های عصبی مصنوعی

### مقدمه

بیان می‌شود. شیر طبیعی بدون یک ماده نگهدارنده، دارای عمر ماندگاری نسبتاً کوتاهی است و محیط ایده‌آلی برای رشد و تکثیر میکروارگانیسم‌ها بوده و بسیار مستعد فساد است. این محصول با توجه به گستردگی دامنه‌ی مصرفی که دارد، می‌تواند به عنوان یک عامل مؤثر برای انتقال بیماری‌های ناشی از مصرف مواد غذایی مانند سالمونلوز، تب مالت، سل و غیره عمل کند (Fuca et al., 2013). بر خلاف بعضی از غذاها و نوشیدنی‌ها، اضافه کردن مواد افزودنی در شیر به منظور افزایش عمر ماندگاری آن، ممنوع است. بر اساس تعاریف ارائه شده از سوی کدکس غذایی (Anonymous, 2009)، شیر خام تازه باید دارای مزه، رنگ و بوی طبیعی و بدون آغوز و آلودگی باشد و همچنین باید عاری از هر گونه افزودنی مانند آب، قند، نمک، شیر خشک، مواد خنثی کننده، جوش شیرین، مواد نگهدارنده، آب اکسیژنه، فرمالین، شوینده‌ها و غیره باشد (Mousavi et al., 2011).

از جمله مهمترین تغییرات رخ داده در شیر بر اثر افزایش میزان بار میکروبی در این ماده غذایی، افزایش میزان اسیدیته‌ی شیر است که منجر به لخته شدن شیر شده و نهایتاً منجر به

امروزه تعداد افرادی که دچار بیماری‌های ناشی از مصرف مواد غذایی نامناسب می‌شوند در حال افزایش است. یکی از عوامل این بیماری‌ها، مسمومیت ناشی از مصرف مواد غذایی تقلبی است. جدا از غیر قانونی بودن تقلب، مصرف مواد تقلبی، تهدیدی برای سلامتی افراد جامعه به شمار می‌آید و در بعضی مواقع حتی منجر به مرگ نیز می‌شود (Spink et al., 2011). اضافه کردن مواد افزودنی به منظور افزایش عمر ماندگاری، بالا بردن بازده و یا حتی پوشاندن وجود یک تقلب دیگر، از جمله مشکلاتی است که در صنعت مواد غذایی روز به روز بیشتر می‌شود. شیر دارای مقادیر بالایی از پروتئین، ویتامین، لاکتوز، چربی، کلسیم و مواد معدنی است و به عنوان یک غذای کامل، از اهمیت بالایی برخوردار است، به طوری که امروزه یکی از شاخص‌های توسعه جوامع انسانی، مصرف شیر و فرآورده‌های آن

غذایی از جمله تشخیص کیفیت میوه‌ها ( Torri *et al.*, 2010; Zakaria *et al.*, 2012; Foroughirad *et al.*, 2014; Sanaeifar Panigrahi *et al.*, 2006; Tian *et al.*, 2015a *et al.*، گوشت (، 2013)، ماهی (Guney & Atasoy, 2015) و روغن‌ها (Haddi *et al.*, 2013) انجام شده است. برای شیر و فرآورده‌های لبنی، تعدادی از پژوهشگران گزارش داده‌اند که براساس تجزیه و تحلیل مؤلفه‌های اصلی (PCA)، تجزیه و تحلیل تفکیک خطی (LDA) و یا شبکه‌های عصبی مصنوعی (ANN) به عنوان تکنیک‌های شناسایی الگو، بینی الکترونیکی می‌تواند انواع مختلف نمونه‌های شیر را از لحاظ مدت زمان ماندگاری و تشخیص شیر سالم و ناسالم، از یکدیگر تفکیک نماید (Gutierrez-Mendez *et al.*, 2008; Wang *et al.*, 2010; Botre *et al.*, 2009). در رابطه با ارزیابی اصالت محصولات نیز تحقیقاتی زیادی به منظور پی‌بردن به تقلب در روغن‌ها (Zheng *et al.*, 2002; Oliveros *et al.*, 2006; Tian *et al.*, 2013)، چای (Bhattacharyya *et al.*, 2008) و زعفران (Yu *et al.*, 2007; Heidarbeigi *et al.*, 2015)، انجام شده است. قابلیت یک ماشین بویایی تجاری (PEN2) را برای تشخیص تمایز بین شیر، شیر بازسازی شده با شیر خشک و درصد‌های مختلف تقلب مورد بررسی قرار دادند. نتایج حاصل از روش‌های LDA و PCA به ترتیب با دقت‌های ۹۸/۵۵٪ و ۹۸/۷۷٪ توانایی بینی الکترونیکی در تفکیک بین نمونه‌ها با درصد‌های مختلف تقلب را نشان دادند.

بر اساس دانش نویسندگان این مقاله و جستجوی منابع علمی تاکنون پژوهشی در رابطه با بررسی تقلب فرمالین در شیر خام با استفاده از ماشین بویایی (بینی الکترونیکی) در دنیا گزارش نشده است. هدف از این پژوهش بررسی قابلیت سامانه‌ی ماشین بویایی بر پایه حسگرهای گازی اکسید فلزی در تشخیص وجود فرمالین در شیر خام به عنوان یکی از مواد افزودنی غیر مجاز می‌باشد. همچنین توانایی روش‌های تفکیک الگو در طبقه‌بندی بین درصد‌های مختلف تقلب مورد بررسی قرار گرفت.

## مواد و روش‌ها

### آماده سازی نمونه‌ها

در طی انجام آزمایش‌ها شیر تازه از دامداری دانشگاه شهرکرد تهیه و در دمای °C ۴ نگهداری شد. برای تهیه نمونه‌ها با درصد‌های مختلف تقلب، یک ساعت قبل از انجام آزمایش‌ها با بینی الکترونیکی، فرمالین با نسبت‌های ۰٪ و ۰/۰۵٪ و ۰/۱٪ و ۰/۲٪ و ۰/۳٪ (بر مبنای حجم) به شیر خام افزوده شد. برای هر آزمایش مقدار ۱۰۰ cc از نمونه‌های آماده شده در محفظه

عدم دریافت آن در کارخانجات لبنی می‌گردد. بعضی از افراد برای جلوگیری از افزایش میزان بار میکروبی در شیر، اقدام به افزودن مواد غیر مجاز و بعضاً مصنوعی می‌کنند که مهمترین این مواد، فرمالین، آب اکسیژنه، وایتکس، شوینده‌ها و غیره است (Mansour *et al.*, 2012). از فرمالین در تولید محصولات ضد عفونی‌کننده و استریل‌کننده استفاده می‌شود و با توجه به در دسترس بودن آن در مراکز تولید و جمع‌آوری شیر، بررسی وجود آن در شیر از اهمیت بالایی برخوردار است. فرمالین در گروه مواد سرطان‌زا برای انسان طبقه‌بندی می‌شود که باعث سرطان نازوفارنکس و احتمالاً سرطان خون می‌شود. استنشاق فرمالین سبب آسیب به سیستم تنفسی، چشم‌ها و پوست افراد شده و همچنین خوردن محلول آن می‌تواند سبب تحریکات و درد شدید در ناحیه دهان، گلو، مری و سیستم گوارشی شود (Tang *et al.*, 2009).

تاکنون برای تشخیص تقلب در شیر از روش‌های مختلفی مانند کروماتوگرافی مایع با عملکرد بالا<sup>۱</sup> (Veloso *et al.*, 2002)، کروماتوگرافی گازی-طیف‌سنج جرمی<sup>۲</sup> (Lutter *et al.*, 2011)، طیف‌سنجی رامان<sup>۳</sup> (Nieuwoudt *et al.*, 2016) و روش‌های آنزیمی<sup>۴</sup> (Ren *et al.*, 2014) استفاده شده است. بیشتر این روش‌ها وقت‌گیر بوده و به ابزارهای دقیق و گران-قیمت نیاز دارند. همچنین، حضور افراد متخصص برای کار با ابزارها، آماده‌سازی پر زحمت نمونه‌ها و زمان طولانی انجام اندازه‌گیری‌ها از معایب روش‌های مذکور است (Das *et al.*, 2015). یکی از روش‌های نوین در سنجش کیفیت مواد غذایی، استفاده از ماشین بویایی (بینی الکترونیکی) است. این دستگاه حس بویایی انسان را شبیه‌سازی کرده و به وسیله یک آرایه‌ی حسگری از حسگرهای غیر اختصاصی (*Non-specific*) سعی در تشخیص رد اثر بوی موجود در فضای بالای نمونه‌ها دارد (Ghasemi-Varnamkhasti *et al.*, 2011a; Ghasemi-Varnamkhasti *et al.*, 2011b; Ghasemi-Varnamkhasti *et al.*, 2015). بطور کلی، بینی الکترونیک ابزاری غیر مخرب و با قابل اعتماد بالا است که نسبت به سایر روش‌ها مزیت‌هایی همچون کاربری آسان، هزینه‌ی کم و سرعت بالا دارند (Tian *et al.*, 2013; Loutfi *et al.*, 2015).

تاکنون تحقیق‌های زیادی با استفاده از ماشین بویایی (بینی‌های الکترونیکی) برای ارزیابی کیفیت و سلامت مواد

1. High performance liquid chromatography  
2. Gas Chromatography -Mass Spectrometry  
3. Raman spectroscopy  
4. Enzyme-Linked Immunosorbent Assay

ماشین‌های بویایی استفاده می‌شوند (Sanaeifar et al., 2015b). حسگرهای استفاده شده و مشخصات آنها در جدول (۱) آورده شده است. بنا بر توصیه کارخانه‌های سازنده‌ی حسگرها، ولتاژ مستقیم ۵ ولت برای رساندن دمای سطح حسگر به مقدار مناسب (۳۰۰-۵۰۰ °C) به گرم‌کن حسگرها داده شد. همچنین به منظور اطمینان از کارکرد حسگرها در دمای توصیه شده و رسیدن به پایداری دمایی، ۳۰ دقیقه قبل از شروع آزمایش‌ها، مجموعه‌ی حسگری توسط یک بورد واسط شروع به کار کرده تا به دمای مورد نظر برسد. ۱۰۰ cc از نمونه‌های آماده شده در محفظه‌ی نمونه‌گیری کاملاً عایق با گنجایش یک لیتر قرار داده شد. محفظه نمونه‌ها ۱۵ دقیقه قبل از شروع آزمایش‌ها و فرایند داده‌برداری به منظور تولید مواد فرار و پر شدن فضای بالای نمونه، در حمام آب با دمای ۳۵ °C قرار داده شدند. این زمان برای رسیدن به تعادل دمایی شیر از ۴ °C به ۳۵ °C کافی بود (Lozano et al., 2005).

مخصوص نمونه‌گیری ریخته و برای رسیدن به تعادل دمایی، در حمام آب گرم قرار داده شد (Lozano et al., 2005).

#### ماشین بویایی (بینی الکترونیکی)

به منظور تشخیص وجود فرمالین در شیر، یک سامانه ماشین بویایی طراحی و ساخته شد. این سامانه شامل قسمت‌های محفظه‌ی نمونه‌گیری برای جمع‌آوری گازهای نمونه، مجموعه‌ی آرایه‌ی حسگری برای تشخیص گاز نمونه‌ها، سامانه‌ی تحویل و جمع‌آوری داده، حمام آب گرم، شیرهای پنوماتیکی، پمپ و الگوریتم‌های تشخیص و تحلیل داده می‌باشد. طرح شماتیک سامانه در شکل (۱) آورده شده است. مجموعه حسگرها شامل ترکیبی از حسگرهای مختلف با نام‌های تجاری (Hanwi, ) MQ (China) ، TGS (Glenview, USA) و (Osaka, Japan) FIS می‌باشد که شامل ۸ حسگر نیمه‌هادی اکسید فلزی است که هر کدام به ترکیبات خاصی از مواد فرار در نمونه‌ها واکنش نشان می‌دهند. این حسگرها به دلیل پایداری شیمیایی بالا، عمر زیاد، پاسخ کم به رطوبت و قیمت مناسب به طور گسترده در

جدول ۱. نام، مشخصات و محدوده‌ی تشخیص آرایه‌ی حسگری بینی الکترونیکی

شماره حسگر	نشان تجاری	محدوده‌های تشخیص (ppm)	کاربردهای اصلی
S1	MQ3	۰/۰۵ - ۱۰	الکل
S2	MQ4	۲۰۰ - ۱۰۰۰۰	متان، گاز طبیعی
S3	MQ135	۱۰ - ۳۰۰ (آمونیاک، الکل، هیدروژن)	الکل، آمونیاک، بنزن، دود، دی‌اکسید کربن
S4	FIS	۱-۱۰ (سولفید هیدروژن)	کنترل کیفیت هوا
S5	TGS813	۱۰ - ۱۰۰ (اتانول، آمونیاک)	متان، پروپان، بوتان
S6	TGS822	۵۰ - ۱۰۰۰۰	بخار حلال‌های آلی
S7	TGS2602	۱ - ۳۰	سولفید هیدروژن، آمونیاک، تولوئن
S8	TGS2620	۵۰ - ۱۰۰۰	الکل، بخار حلال‌های آلی

فرآیند نمونه‌برداری شامل سه مرحله تصحیح خط مبنا، اندازه‌گیری و پاک‌سازی محفظه حسگرها است (شکل ۲). مرحله‌ی تصحیح خط مبنا، به منظور رساندن پاسخ آرایه‌ی حسگرها به حالت پایدار انجام می‌شود. در این مرحله گاز حامل توسط پمپ به مدت ۱۸۰ ثانیه به محفظه حسگرها تزریق شد (شیر برقی (۱) باز و شیرهای برقی (۲) و (۳) بسته می‌باشند). در مرحله اندازه‌گیری، گاز حامل با ورود به محفظه‌ی نمونه، گاز فضای هد شیر را به محفظه‌ی حسگرها منتقل می‌کند. مدت زمان ۲۲۰ ثانیه برای رسیدن پاسخ حسگرها به حالت ماکزیمم کافی بود (شیرهای برقی (۲) و (۳) باز و شیر برقی (۱) بسته می‌باشند). مرحله پاک‌سازی برای رساندن پاسخ حسگرها به خط مبنا و آماده‌سازی سامانه برای آزمایش‌های بعدی، انجام

می‌شود. گاز حامل به مدت ۴۰۰ ثانیه به محفظه‌ی حسگرها تزریق شد (شیر برقی (۱) باز و شیرهای برقی (۲) و (۳) بسته می‌باشند). لازم به ذکر است که زمانبندی سامانه برای هر نوع کاربردی منحصر به فرد است و با تغییر کاربری سامانه ماشین بویایی، باید دوباره این مراحل زمانبندی شوند (Ghasemi-Varnamkhashti, 2011). انجام آزمایش‌های متعدد و پایش پاسخ حسگرها تعیین می‌شود. در این پژوهش از گاز اکسیژن به عنوان گاز حامل استفاده شد. همچنین به منظور حذف اثر تغییرات فشار گاز ورودی روی حسگرها، پمپ با مقدار دبی ثابت ۱/۳ lit/min به کار گرفته شد. تأثیر مراحل کاری سامانه روی پاسخ حسگر TGS822 در شکل (۲) نشان داده شده است.

ویژگی برای مجموعه حسگرها انجام می‌شود به این صورت که ماکزیمم پاسخ حسگر در مرحله تزریق گاز فضای هد نمونه به عنوان یک ویژگی در نظر گرفته می‌شود.

آخرین مرحله از پیش‌پردازش داده‌ها قبل از استفاده از روش‌های تحلیل الگو، نرمال‌سازی داده‌ها است. از رابطه (۲) برای نرمال‌سازی داده‌های هر حسگر (k) در محدوده (0,1) استفاده شد.

$$Y_s^k = \frac{X_s^k - \min_{V_k}[X_s^k]}{\max_{V_k}[X_s^k] - \min_{V_k}[X_s^k]} \quad (\text{رابطه } 2)$$


### تحلیل داده‌ها

#### تحلیل مؤلفه‌های اصلی (PCA<sup>۵</sup>)


از تحلیل مؤلفه‌های اصلی برای کاهش بعد داده‌ها و ارزیابی مقدماتی شباهت بین کلاس‌ها استفاده شد. PCA یک تبدیل خطی متعامد است که نتایج نمودارهای گرافیکی آن اجازه می‌دهند تا به آسانی، تجسمی از تمام اطلاعات موجود در یک مجموعه داده ایجاد شود. همچنین این روش به درک این مطلب که یک نمونه با چه نسبتی از سایر نمونه‌ها متفاوت بوده (نمودار اسکور) و کدام متغیرها بیشترین سهم در این تمایز را دارند (نمودار لودینگ) کمک می‌کند. نمودارهای اسکور معمولاً برای مطالعه طبقه‌بندی داده‌ها استفاده می‌شوند در حالیکه نمودارهای لودینگ اطلاعاتی در رابطه با اهمیت نسبی مجموعه حسگر در تحلیل مؤلفه‌های اصلی ارائه می‌دهد (Yu et al., 2007; Ghasemi-Varnamkhasti et al., 2012). در این پژوهش، از این روش تشخیص الگو با انجام کاهش ابعاد از هشت متغیر به دو یا سه مؤلفه اصلی و حفظ بیشترین محتوای اصلی اطلاعات در مجموعه داده‌ها، برای بررسی تمایز بین نمونه‌های شیر با درصد‌های مختلف تقلب استفاده شد.

#### تحلیل تفکیک خطی (LDA<sup>۶</sup>)

تحلیل تفکیک خطی یک روش متداول آماری برای کاهش ابعاد بوده و بطور گسترده در پژوهش‌های مختلف بکار برده شده است (Yu et al., 2016; Rutolo et al., 2016). این روش در واقع یک روش طبقه‌بندی است که در آن کلاس‌ها به گونه‌ای در نظر گرفته می‌شوند که توزیع نرمال و پراکندگی یکسانی داشته باشند. هدف این تحلیل، تصویر نمونه‌ها از فضای N بعدی به یک خط است. برای مسائلی با K کلاس، تعداد m = min(K - 1, N) خط مورد نیاز است. بنابراین می‌توان گفت تصویر کردن نمونه‌ها با تعداد m تابع خطی قابل انجام



شکل ۱. طرح‌واره سامانه ماشین بویایی برای تشخیص تقلب فرمالین در شیر



شکل ۲. مراحل تصحیح خط مبنا، اندازه‌گیری و پاکسازی برای پاسخ حسگر TGS822

### استخراج ویژگی


بعد از جمع‌آوری و ذخیره‌سازی داده‌ها و به منظور آماده‌سازی پاسخ حسگرها برای تحلیل‌های تشخیص الگو، پیش‌پردازش اطلاعات انجام می‌شود. پیش‌پردازش شامل سه مرحله تصحیح خط مبنا، فشرده‌سازی و نرمال‌سازی داده‌ها است. هدف از تصحیح خط مبنا جبران رانش<sup>۱</sup> و افزایش کیفیت پاسخ حسگرها است. روش‌های مختلفی از جمله روش اختلافی<sup>۲</sup>، نسبی<sup>۳</sup> و کسری<sup>۴</sup> بدین منظور وجود دارد (Kiani et al., 2016). در این پژوهش، از روش کسری برای تصحیح خط مبنا استفاده شد (رابطه ۱). این روش علاوه بر تصحیح خط مبنا، داده‌ها را نیز نرمال می‌کند و بطور گسترده در حسگرهای نیمه‌هادی اکسید فلزی (MOS) استفاده می‌شود (Pearce et al., 2003).

$$Y_s(t) = \frac{X_s(t) - X_s(0)}{X_s(0)} \quad (\text{رابطه } 1)$$

در این رابطه  $X_s(0)$  کمترین پاسخ حسگر قبل از مرحله اندازه‌گیری،  $X_s(t)$  پاسخ حسگر در زمان t و  $Y_s$  پاسخ پیش‌پردازش شده حسگر است. فشرده‌سازی پاسخ حسگرها با هدف کاهش تعداد توصیف‌گرهای هر پاسخ و ایجاد یک بردار

1 Drift  
2. Differential  
3. Relative  
4. Fractional

توابع هسته (کرنل) به یک فضای چند بعدی با بعد بزرگتر از بعد اولیه نگاشت می‌شوند. سپس یک ابرصفحه (مرز تصمیم-گیری) ساخته می‌شود که با حداکثر فاصله‌ی ممکن، بردارهای ورودی را از هم جدا می‌کند. به این ابرصفحه، ابرصفحه با حداکثر مرز جداکننده گفته می‌شود. در دو طرف این ابرصفحه، دو ابرصفحه موازی آن قرار دارند که هیچ داده‌ای در مرز بین این دو ابرسطح قرار نمی‌گیرد. به نمونه‌هایی که بر روی این دو ابرصفحه قرار می‌گیرند، بردار پشتیبان گفته می‌شود (شکل ۳). هر چه فاصله بین دو ابرصفحه موازی بیشتر باشد، خطای طبقه‌بندی هم کمتر خواهد بود (Cristianini & Taylor, 2000; Haddi et al., 2013).



شکل ۳. ابرصفحه و بردارهای پشتیبان در ماشین بردار پشتیبان (Palaniswami et al., 2006).

در ماشین بردار پشتیبان بیشتر برای طبقه‌بندی داده‌ها از دو روش C-SVM و Nu-SVM استفاده می‌شود که مبتنی بر راه‌های متفاوت برای به حداقل رساندن تابع خطا می‌باشند. پارامتر C در طبقه‌بندی به روش C-SVM بر اساس اطلاع از نویز موجود در داده‌ها انتخاب می‌شود. این مقدار را می‌توان از طریق روش‌های اعتبارسنجی بهینه‌سازی کرد. زمانی که طبقه‌بندی Nu-SVM استفاده می‌شود، پارامتر Nu باید تعریف شود. Nu به عنوان مرز بالایی از خطاها و حد پایین برای بردار پشتیبان عمل می‌کند. در نتیجه با افزایش Nu، در زمان افزایش حاشیه جداسازی کلاس‌ها، خطاها افزایش می‌یابند (Fan et al., 2005; Sanaeifar et al., 2014).

اگر چه روش ماشین بردار پشتیبان از ابتدا برای طبقه‌بندی خطی داده‌ها طراحی شد ولی با استفاده از توابع کرنل مختلف، می‌تواند در طبقه‌بندی غیر خطی داده‌ها نیز استفاده شود. معمولاً در این روش از چهار تابع کرنل خطی، چند جمله‌ای، تابع پایه شعاعی و تابع سیگموئید بیشتر استفاده می‌شود.

است. اگرچه PCA و LDA هر دو از روش‌های تصویر کردن داده‌ها از محیط چند بعدی به محیطی با بعد کمتر هستند، اما روش LDA به منظور بهینه کردن تفکیک پذیری بین گروه‌ها، واریانس بین گروهی را بیشینه و واریانس درون گروهی را کمینه می‌کند (Sanaeifar et al., 2015b). این روش تشخیص الگو با استفاده از نرم افزار x10.3 Unscrambler انجام شد.

### شبکه‌های عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی، به عنوان یک سیستم پردازش داده با الهام از سیستم عصبی زیستی، به عنوان یک مدل محاسباتی سعی در شبیه‌سازی سیستم ادراک انسان داشته و یک ابزار شناخته شده برای حل مسائل پیچیده و غیر خطی است (Tohidi, 2010). شبکه عصبی پرسپترون چندلایه یکی از شبکه‌های پیشخور است که در تحلیل‌های کمومتریک (کاربرد علوم آمار، کامپیوتر، ریاضی و گرافیک برای استخراج اطلاعات و درک بهتر داده‌ها)، برای حل مسائل تشخیص و پیش‌بینی الگو به صورت نظارت شده یا نظارت نشده استفاده می‌شود. وزن و ساختار شبکه از طریق آموزش و یادگیری به دست آمده و شبکه می‌تواند خود را با شرایط تطبیق دهد و به طور کلی دارای سه لایه ورودی، پنهان و خروجی می‌باشند (Ding et al., 2015). شبکه عصبی به عنوان یکی از روش‌های کمومتریکس از پتانسیل بالایی برای تحلیل سیگنال‌های غالباً غیرخطی حسگرهای بینی الکترونیکی برخوردار هستند (Oliveros et al., 2002). در این پژوهش نیز به منظور پیش‌بینی کمی وجود تقلب در شیر، از شبکه‌های عصبی مصنوعی با الگوریتم پس انتشار خطا و تکنیک اعتبارسنجی متقابل با یک نمونه خارج شده<sup>۱</sup> استفاده شد. در این روش اعتبارسنجی همزمان با ساخت مدل نمونه‌ای از دسته داده‌ی کالیبراسیون خارج شده و از باقی برای ساخت مدل استفاده می‌شود. سپس مدل ساخته شده با داده‌ی خارج شده (که متعلق به دسته داده‌ی کالیبراسیون است) تست می‌شود. این کار برای تمامی نمونه‌های موجود در دسته داده‌ی کالیبراسیون انجام می‌شود.

### ماشین بردار پشتیبان (SVM<sup>۲</sup>)

ماشین بردار پشتیبان یکی از روش‌های یادگیری با نظارت است که بر اساس تئوری یادگیری آماری استوار است و در حل بسیاری از مسائل رگرسیون و طبقه‌بندی استفاده می‌شود (Sanaeifar et al., 2014). در این روش، بردارهای ورودی توسط

1. Artificial Neural Networks

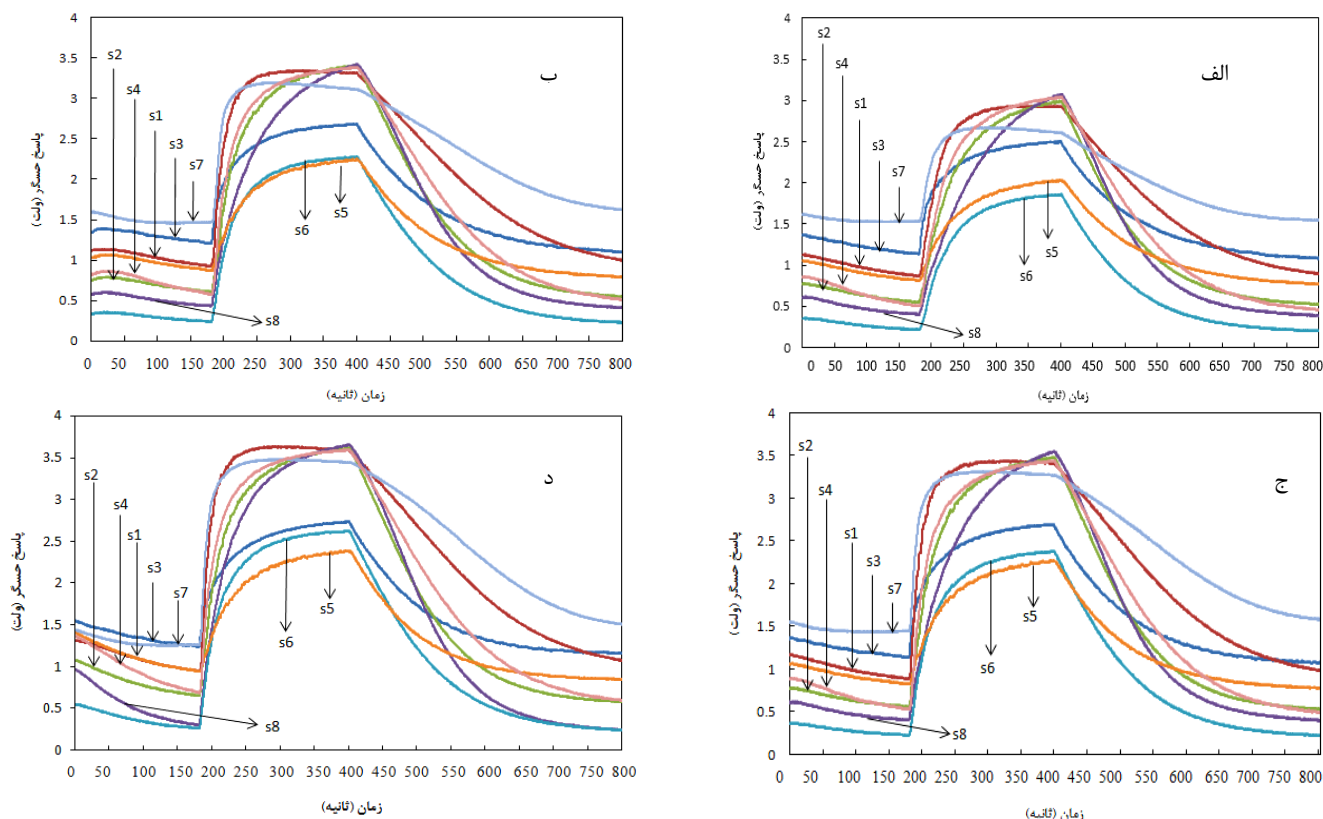
2. Leave one out cross validation

3. Support vector machine

## نتایج و بحث


پاسخ ولتاژی حسگرها به تغییر الگوی بو در نمونه‌ها برای هر پنج گروه شیر (شیر خالص و درصدهای مختلف تقلب فرمالین) با ۱۱ تکرار، اندازه‌گیری شده و نهایتاً پاسخ آرایه‌ی حسگری برای ۵۵ نمونه ثبت و ذخیره‌سازی شد. سپس میانگین ۵ داده انتهایی مرحله تزریق گاز نمونه به عنوان توصیف‌کننده سیگنال -

ها، استخراج و از ماتریس ویژگی  $8 \times 55$  به عنوان ورودی روش‌های تجزیه و تحلیل‌های کومتریکس استفاده شد. در شکل (۴) پاسخ‌های ثبت شده‌ی حسگرها در واکنش به مقادیر مختلف فرمالین در شیر نشان داده شده است. همان‌طور که در شکل مشخص است با افزایش مقدار فرمالین در نمونه، پاسخ خروجی حسگرها در مرحله‌ی اندازه‌گیری افزایش یافته است.



شکل ۴. پاسخ آرایه‌ی حسگری به مقادیر مختلف فرمالین در شیر، (الف) شیر خام، (ب) ۰/۱٪ فرمالین، (ج) ۰/۲٪ فرمالین، (د) ۰/۳٪ فرمالین


۹۹ نمونه‌های زعفران اصلی و تقلبی (تقلب گلرنگ) را از یکدیگر تفکیک کردند.



شکل ۵. نمودار اسکور وجود فرمالین با درصدهای مختلف در شیر

در شکل (۵) نمودارهای اسکور برای دو مولفه اصلی نشان داده شده است. این نمودارها به منظور تشخیص تمایز بین گروه نمونه‌ها برای فرایند شناسایی الگو استفاده می‌شوند. همان‌طور که در شکل نشان داده شده است، تمایز مناسبی بین نمونه‌های شیر خالص و نمونه‌های شیر تقلبی وجود دارد. دو مؤلفه‌ی اصلی PC1 و PC2 به ترتیب ۸۰٪ و ۱۳٪ واریانس بین نمونه‌ها و در مجموع ۹۳٪ واریانس کل داده‌ها را توصیف کردند. نمونه‌های مربوط به تقلب ۰/۲٪، به مقدار بسیار کمی با دو گروه تقلب ۰/۱٪ و ۰/۳٪، همپوشانی دارند. این وضعیت بیانگر این مطلب است که پاسخ حسگرها به تقلب ۰/۲٪، کمی مشابه پاسخ دو تقلب دیگر است هر چند بین شیر خالص و سایر نمونه‌ها در سطوح مختلف تقلب، تفکیک‌پذیری بالایی وجود دارد. (2015) Heidarbeygi *et al* با دو مؤلفه‌ی اصلی PC1 و PC2 به مقدار ٪

همچنین از تحلیل تفکیک خطی نیز به منظور بررسی قابلیت سامانه در تفکیک بین ترکیبات فرار متصاعد شده در فضای هد نمونه‌ها در غلظت‌های مختلف فرمالین اضافه شده به شیر استفاده شد. در نمودار (۷) نتایج حاصل از تحلیل LDA نشان داده شده است که دقت طبقه‌بندی  $80/1\%$  را با استفاده از اعتبارسنجی متقابل با یک نمونه خارج شده حاصل نمود.



شکل ۷. نمودار اسکور تحلیل تفکیک خطی پنج گروه مختلف شیر


از شبکه‌ی عصبی پرسپترون برای طبقه‌بندی درصد‌های مختلف تقلب فرمالین در شیر استفاده شد. بدین منظور با در نظر گرفتن تعداد حسگرها، ۸ نرون برای ورودی و ۵ نرون (با توجه به تعداد سطوح تقلب) برای لایه خروجی شبکه در نظر گرفته شد. با آموزش شبکه با تعداد مختلف نرون در لایه مخفی، شبکه‌ی بهینه با تعداد ۷ نرون در لایه مخفی ایجاد شد. بنابراین شبکه‌ی عصبی با ساختار ۸-۷-۵ برای طبقه‌بندی درصد‌های مختلف تقلب در شیر بالاترین دقت را داشت. در آموزش شبکه از تابع انتقال تانژانت هایپربولیک و روش یادگیری ممنوم استفاده شد. ماتریس اغتشاش حاصل از این شبکه در جدول (۲) نشان داده شده است.

جدول ۲. ماتریس اغتشاش با ۷ نرون در لایه‌ی مخفی

مشاهده/پیش‌بینی	۱	۲	۳	۴	۵
۱	۳	۰	۰	۰	۰
۲	۰	۲	۰	۰	۰
۳	۰	۰	۳	۰	۰
۴	۰	۰	۰	۳	۰
۵	۰	۰	۰	۰	۳

(۱)  $0\%$  فرمالین، (۲)  $0/50\%$  فرمالین، (۳)  $0/1\%$  فرمالین، (۴)  $0/2\%$  فرمالین، (۵)  $0/3\%$  فرمالین

برای اطلاع یافتن از میزان تأثیر هر کدام از حسگرها در تحلیل‌های شناسایی الگو، حسگرها در نموداری به نام نمودار لودینگ<sup>۱</sup> با ضرایب مقادیر ویژه تصویر شدند (شکل ۶). هر چه مقدار لودینگ حسگری روی یک مؤلفه‌ی اصلی بزرگتر باشد، بیانگر نقش بیشتر آن حسگر در تشخیص و تمایز میان نمونه‌های شیر با درصد‌های مختلف تقلب است. بنابراین می‌توان با حذف حسگر یا حسگرهایی که کمترین سهم را در تشخیص تمایز بین گروه‌ها دارند، علاوه بر کاستن از پیچیدگی فرآیند تحلیل داده، هزینه‌ی ساخت آرایه حسگری را نیز کاهش داد. شکل (۷) این نمودار لودینگ را برای دو مؤلفه‌ی اصلی نشان می‌دهد. مطابق شکل، حسگرهای S2 (MQ4)، S4 (FIS)، S6 (TGS822) و S8 (TGS2620) مقادیر ضریب لودینگ دارند. حسگرهای S2 و S6 با وجود اینکه مقدار ضریب لودینگ بالایی دارند اما با توجه به نزدیکی مقادیر آنها به یکدیگر، این دو حسگر تأثیر تقریباً یکسانی در شناسایی الگو داشته‌اند و می‌توان فقط یکی از آنها را در فرآیند تحلیل داده استفاده کرد. مطابق برگه مشخصات ارائه شده از طرف شرکت سازنده حسگرها، حسگر S2 بالاترین حساسیت را به متان دارد و حسگر S6 به بخار حلال‌های آلی حساس می‌باشد. نتایج (Rock et al. 2010) نشان داد که حسگر (AS-MLK) با حساسیت بالا به گاز متان، در مقایسه با دو حسگر (TGS2620) و (TGS2602) از حساسیت بالاتری در تشخیص فرمالدهید برخوردار است. با توجه به این که یکی از کاربردهای حسگر S8 تشخیص آلدئید-ها از جمله فرمالدهید می‌باشد، حساسیت بالای این حسگر به وجود فرمالین در شیر از جمله موارد قابل انتظار است. حسگر S7 (TGS2602) نسبت به سایر حسگرها در شناسایی بین الگوها از کارایی کمتری برخوردار است. نتایج تحقیقات Zhang et al. (2008) نیز نشان داد که این حسگر نسبت به حسگرهای (TGS813) و (TGS2620) کمترین پاسخ را نسبت به فرمالدهید دارد.



شکل ۶. نمودار لودینگ آرایه حسگری مربوط به دو مؤلفه‌ی اصلی

( $r$ ) در جدول (۳) نشان داده شده است. (Botre et al. 2009) نیز داده‌های بینی الکترونیکی را با تکنیک شبکه‌های عصبی مصنوعی برای شیر سالم و فاسد با دقت ۹۶٪ طبقه‌بندی کردند.

دقت طبقه‌بندی شبکه عصبی مصنوعی برای تمامی کلاس‌ها، ۱۰۰ درصد به دست آمد. کمترین و بیشترین میزان میانگین مربعات خطا به ترتیب مربوط به کلاس (۵) به مقدار ۰/۰۰۱۳۴ و کلاس (۴) به مقدار ۰/۰۰۳۳۳ به دست آمد. دقت طبقه‌بندی، میانگین مربعات خطا (MSE) و میزان همبستگی

جدول ۳. عملکرد بهینه شبکه عصبی مصنوعی در طبقه‌بندی گروه‌های مختلف شیر

عملکرد	۰٪ فرمالین	۰/۵٪ فرمالین	۰/۱٪ فرمالین	۰/۲٪ فرمالین	۰/۳٪ فرمالین
میانگین مربعات خطا	۰/۰۰۱۳۴	۰/۰۰۳۳۳	۰/۰۰۳۲۰	۰/۰۰۱۷۴	۰/۰۰۱۷۲
ضریب همبستگی	۰/۹۹۷	۰/۹۹۰	۰/۹۹۵	۰/۹۹۶	۰/۹۹۹
دقت طبقه‌بندی (درصد)	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰

پارامترهای بهینه SVM برای این تابع،  $Nu$  (۰/۰۱) و  $\gamma$  (۰/۱۲۵) بدست آمد. همچنین دقت آموزش و اعتبارسنجی طبقه‌بندی برای این تابع به ترتیب ۱۰۰٪ و ۹۰/۹۱٪ حاصل شد. نتایج حاصل از این روش در جدول (۴) آورده شده است.

همچنین برای طبقه‌بندی داده‌ها، ماشین بردار پشتیبان از نوع  $Nu$ -SVM استفاده شد، پارامترهای  $Nu$  و  $\gamma$  با سعی و خطا و از طریق به حداقل رساندن خطای اعتبارسنجی تعیین شدند. از چهار نوع تابع کرنل استفاده شده، تابع چندجمله‌ای با درجه سه، بالاترین دقت را در طبقه‌بندی نمونه‌های شیر دارد.


جدول ۴. عملکرد و پارامترهای ماشین بردار پشتیبان

تابع کرنل	پارامتر $Nu$	پارامتر $\gamma$	دقت طبقه‌بندی در آموزش (درصد)	دقت طبقه‌بندی در اعتبارسنجی (درصد)
خطی	۰/۵	-	۸۹/۰۹	۸۳/۶۳
چندجمله‌ای	۰/۰۱	۰/۱۲۵	۱۰۰	۹۰/۹۱
گوسی	۰/۳۳۶	۰/۱۲۵	۹۴/۵۵	۸۹/۰۹
سیگموئید	۰/۸۲۶	۰/۰۱	۶۱/۸۲	۶۰

کلاس‌های مختلف شیر داشتند. از این امر می‌توان برای انتخاب حداقل تعداد حسگر برای تمایز مطلوب بین کلاس‌ها و به منظور کاهش هزینه‌ها استفاده کرد.

### نتیجه‌گیری کلی

قابلیت یک سامانه ماشین بویایی بر پایه هشت حسگر نیمه هادی اکسید فلزی (MOS) در ترکیب با روش‌های شناسایی الگو در آشکارسازی وجود فرمالین در شیر خام مورد بررسی قرار گرفت. تحلیل مؤلفه‌های اصلی نشان داد که با دو مؤلفه اصلی اول، ۹۳٪ از واریانس داده‌ها قابل توصیف است. از بین سه روش تفکیک الگو استفاده شده به ترتیب شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان با تابع کرنل چند جمله‌ای، نسبت به تحلیل تفکیک خطی از قابلیت بالاتری در تفکیک نمونه‌های شیر (درصدهای تقلب ۰٪، ۰/۰۵٪، ۰/۱٪، ۰/۲٪ و ۰/۳٪ (بر مبنای حجم)) برخوردار بودند. براساس نتایج به دست آمده، ماشین بویایی بر پایه حسگرهای MOS در ترکیب با روش‌های



شکل ۸. جفت حسگرها با بالاترین قدرت تفکیک پذیری

به منظور بررسی جفت حسگرها در تمایز بین کلاس‌ها از ماشین بردار پشتیبان استفاده شد. حسگرهایی که بهترین تمایز بین کلاس‌های مختلف نمونه‌های شیر ایجاد کردند، در شکل (۸) نشان داده شده است. حسگرهای MQ3 و FIS نسبت به سایر جفت حسگرها، تمایز بین نمونه‌ها با درصدهای مختلف تقلب را بهتر مشخص کردند و بهترین ترکیب را برای تشخیص



قابلیت این سامانه برای تشخیص تقلب در سایر محصولات که پتانسیل تقلب را دارند، استفاده شود.

شناسایی الگو توانایی تشخیص تقلب فرمالین در شیر خام را دارد. همچنین تیم پژوهشی این مقاله پیشنهاد می‌کند که از

## REFERENCES

- Anonymous. (2009). Code of Hygiene practice for milk and milk productions, last modified 2009. Codex Alimentarius-CAC/RCP 57-2004.
- Bhattacharyya, N., Bandyopadhyay, R., Bhuyan, M., Tudu, B., Ghosh, D. & Jana, A. (2008). Electronic nose for black tea classification and correlation of measurements with "Tea Taster" Marks. *IEEE Transactions on Instrumentation and Measurement*, 57: 13113-11321.
- Botre, B., Gharpure, D., Shaligram, A. & Sadistap, S. (2009). Semiconductor sensor array based electronic nose for milk, rancid milk and yoghurt odors identification. *IEEE Transaction on Instrumentation and Measurement*, 63: 1482-1491.
- Cristianini, N. & Shawe-Taylor, J. (2000). *An Introduction to support vector machines and other kernel-based learning methods* (1st ed.). Cambridge: Cambridge University Press
- Das, M., Sivaramakrishna, M., Biswas, K., & Goswami, B. (2015). A low cost instrumentation system to analyze different types of milk adulteration. *ISA Transactions*, 56, 268-275.
- Ding, W., Zhang, Y., Kou, L. & Jurick, M. (2015). Electronic nose application for the determination of penicillin G in Saanen goat milk with fisher discriminate and multilayer perceptron neural network analyses. *Journal of Food Processing and Preservation*, 32(6), 927-932.
- Fan, R.E., Chen, P.H. & Lin, C.j. (2005). Working set selection using second order information for training support vector machines. *Journal of Machine Learning Research*, 6: 1889-1918.
- Foroughirad, A., Mohtasebi, S.S., Ghasemi-Varnamkhasti, M. & Omid, M. (2014). Nondestructive evaluation of kiwifruit (cv. Abbot variety) Abbot using electronic nose. *Iranian Journal of Biosystems Engineering*, 45, 1-9, (In Farsi)
- Fuca, N., Pasta, C., Impoco, G., Caccamo, M. & Licitra, G. (2013). Microstructural properties of milk fat globules. *International Dairy Journal*, 31, 44-50.
- Ghasemi-Varnamkhasti, M., Mohtasebi, S.S., Siadat, M., Ahmadi, H. & Razavi, S.H. (2015). From simple classification methods to machine learning for the binary discrimination of beers using electronic nose data. *Engineering in Agriculture, Environment and Food*, 8, 44-51.
- Ghasemi-Varnamkhasti, M., Mohtasebi, S.S., Siadat, M., Lozano, J., Ahmadi, H., Razavi, S.H. & Dicko, A. (2012). Discriminatory power assessment of the sensor array of an electronic nose system for the detection of non alcoholic beer aging. *Czech Journal of Food Sciences*, 30(3), 236-240.
- Ghasemi-Varnamkhasti, M., Mohtasebi, S.S., Siadat, M., Lozano, J., Ahmadi, H., Razavi, S.H. & Dicko, A. (2011a). Aging fingerprint characterization of beer using electronic nose. *Sensors and Actuators B: Chemical*, 159, 51-59.
- Ghasemi-Varnamkhasti, M., Mohtasebi, S.S., Rodriguez-Mendez, M.L., Lozano, J., Razavi, S.H. & Ahmadi, H. (2011b). Potential application of electronic nose technology in brewery. *Trends in Food Science and Technology*, 22(4), 165-174.
- Ghasemi-Varnamkhasti, M. (2011). Design, development and implementation of a metal oxide semiconductor (MOS) based machine olfaction system and bioelectronics tongue to quality change detection of beers coupled with pattern recognition analysis techniques. Ph. D. dissertation, University of Tehran. (In Farsi).
- Guney, S. & Atasoy, A. (2015). Study of fish species discrimination via electronic nose. *Computers and Electronics in Agriculture*, 119, 83-91.
- Gutierrez-Mendez, N., Vallejo-Cordoba, B., Gonzalez-Cordova, A.F. & NevarezMoorillon, G.V. (2008). Evaluation of aroma generation of lactococcus lactis with an electronic nose and sensory analysis. *Journal of dairy Science*, 91: 49-57.
- Haddi, Z., Alami, H., ElBari, N., Tounsi, M., Barhoumi, H., Maaref, A., Jaffrezic-Renault, N. & Bouchikhi, B. (2013). Electronic nose and tongue combination for improved classification of Moroccan virgin olive oil profiles. *Food Research International*, 54, 1488-1498.
- Heidarbeigi, K., Mohtasebi, S.S., Foroughirad, A., Ghasemi-Varnamkhasti, M., Rafiee, S. & Rezaei, K. (2015). Detection of adulteration in saffron samples using electronic nose. *International Journal of Food Properties*, 18: 1391-1401.
- Kiani, S., Minaei, S. & Ghasemi-Varnamkhasti, M. (2016). portable electronic nose as an expert system for aroma-based classification of saffron. *Chemometrics and Intelligent Laboratory Systems*, 156, 148-156.
- Loutfi, A., Coradeschi, S., Mani, G.K., Shankar, P. & Rayappan, J.B. (2015). Electronic noses for food quality: a review. *Journal of Food Engineering*, 144, 103-111.
- Lozano, J., Santos, J.P. & Horrillo, M.C. (2005). Classification of white wine aromas with an electronic nose. *Talanta*, 67, 610-616.
- Lutter, P., Perroud, M.C., Gimenez, C. & Meyer, L. (2011) Screening and confirmatory methods for the determination of melamine in cow's milk and milk-based powdered infant formula: Validation and proficiency-tests of ELISA, HPLC-UV, GC-MS and LC-MS/MS. *Food Control*, 22(6), 903-913.

- Mansour, A., Elloly, M. & Ahmed, R. (2012). A Preliminary detection of physical and chemical properties, inhibitory substances and preservatives in raw milk. *Internet Journal of Food Safety*, 4, 99-103.
- Mousavi, T., Salehi, M., Mohammad sadegh, M. & mohammadyar, L.(2011). A study of additives residues in raw milk collected from the area PAKDASHT, *Journal of Food Hygiene*, 1, 43-47, (In Farsi)
- Nieuwoudt, M.K., Holroyd, S.E., McGoverin, C.M. & Williams, D.E. (2016). Raman spectroscopy as an effective screening method for detecting adulteration of milk with small nitrogen-rich molecules and sucrose. *Journal of Dairy Science*, 99(4), 2520-2536.
- Oliveros, C.C., Pavon, J.L.P., Pinto, C.G., Laespada, E.F., Cordero, B.M., & Forina, M. (2002). Electronic nose based on metal oxide semiconductor sensors as a fast alternative for the detection of adulteration of virgin olive oils. *Analytica Chimica Acta*, 459: 219–228.
- Palaniswami, M. & Begg.R. (2006) *Computational intelligence for movement sciences: Neural Networks and Other Emerging Techniques*. London: Idea Group Inc
- Panigrahi, S., Balasubramanian, S., Gu, H., Logue, C.M. & Marchello, M. (2006). Design and development of a metal oxide based electronic nose for spoilage classification of beef. *Sensors and Actuators B: Chemical*, 119(1), 2-14.
- Pearce, T.C., Schiffman, S.S., Nagle, H.T. & Gardner, J.W. (2003). *Handbook of Machine Olfaction: Electronic Nose Technology*. Weinheim: Wiley-VCH Verlag GmbH & Co. KGaA
- Ren, Q.R., Zhang, H., Guo, H.Y., Jiang, L., Tian, M. & Ren, F.Z. (2014). Detection of cow milk adulteration in yak milk by ELISA. *Journal of Dairy Science*, 97(10), 6000-6006.
- Rock, F., Barsan, N. & Weimar, U. (2010). System for dosing formaldehyde vapor at the ppb level. *Measurement Science and Technology*, 21, 1-7.
- Rutolo, M.F., Iliescu, D., Clarkson, G.P. & Covington, J.A. (2016). Early identification of potato storage disease using an array of metal-oxide based gas sensors. *Postharvest Biology and Technology*, 116, 50-58.
- Sanaeifar, A., Mohtasebi, S.S., Ghasemi-Varnamkhasti, M., Ahmadi, H. & Lozano, J.(2014).Development and application of a new low cost electronic nose for the ripeness monitoring of banana using computational techniques (PCA, LDA, SIMCA, and SVM). *Czech Journal of Food Sciences*, 32(6), 538–548.
- Sanaeifar, A., Mohtasebi, S.S., Ghasemi-Varnamkhasti, M. & Ahmadi, H. (2015a). Application of MOS based electronic nose for the prediction of banana quality properties. *Measurement*, 82, 150-114.
- Sanaeifar, A., Mohtasebi, S.S., Ghasemi-Varnamkhasti, M. & Ahmadi, H. (2015b). Design, development and implementation of a metal oxide semiconductor (MOS) based machine olfaction system for monitoring of banana ripeness. *Journal of Agricultural Machinery*, 5(1), 111-121, (In Farsi)
- Spink, J. & Moyer, D.C. (2011). Defining the public health threat of food fraud. *Journal of Food Science*, 76, 157–163.
- Tang, X., Bai, Y., Duong, A., Smith, T., Li, L. & Zhang, L. (2009).Formaldehyde in China: Production, consumption, exposure levels, and health effects. *Environment International*, 35(8),1210-1224.
- Tian, X., Wang, J. & Cui, S. (2013). Analysis of pork adulteration in minced mutton using electronic nose of metal oxide sensors. *Journal of Food Engineering*,119(4), 744–749.
- Tohidi, M. (2010). *Simulation of rough rice drying using artificial neural networks*. M. Sc. dissertation, Isfahan University of Technology, Iran.
- Torri, L., Sinelli, N. & Limbo, S. (2010). Shelf life evaluation of fresh-cut pineapple by using an electronic nose. *Postharvest biology and technology*, 56(3), 239-245.
- Veloso, A., Teixeira, N. & Ferreira, I. (2002). Separation and quantification of the major casein fractions by reverse-phase high-performance liquid chromatography and urea-polyacrylamide gel electrophoresis: Detection of milk adulterations. *Journal of Chromatography A*, 967(2), 209-218.
- Wang, B., Xu, S. & Sun, D. (2010). Application of the electronic nose to the identification of different milk flavorings. *Food Research International*, 43: 255-262.
- Yu, H., Wang, J. & Xu, Y. (2007). Identification of adulterated milk using electronic nose. *Sensors and Materials*, 19, 275–285.
- Yu, X., Xu, L., Liu, L. & Zhang, R. (2016). A novel method for qualitative analysis of edible oil oxidation using an electronic nose. *Food Chemistry*, 202, 229-235.
- Zakaria, A., Shakaff, A.Y.M., Masnan, M.J., Saad, F.S.A., Adom, A.H., Ahmad, M.N., Jaafar, M.N., Abdullah, A.H. & Kamarudin, L.M. (2012). Improved maturity and ripeness classifications of magnifera indica cv. harumanis mangoes through sensor fusion of an electronic nose and acoustic sensor. *Sensors*, 12(5), 6023-6048.
- Zheng, H. & Wang, J. (2006). Electronic nose and data analysis for detection of maize oil adulteration in sesame oil. *Sensors and Actuators B: Chemical*, 119(2), 449–455.
- Zheng, S., Xie, C., Hu, M., Li, H., Bai, Z. & Zeng, D. (2008). An entire feature extraction method of metal oxide gas sensors. *Sensors and Actuators B: Chemical*, 132(1), 81–89.