

تشخیص قارچ‌های خوراکی و غیرخوراکی با استفاده از بینی الکترونیکی و هوش مصنوعی

پیمان غلامی^۱، علی نجات لرستانی^{۲*}، ناهید عقیلی ناطق^۳ و سعید عباسی^۴

چکیده

عدم توانایی مردم عادی در تفکیک قارچ‌های خوراکی از قارچ‌های غیرخوراکی و سمی چالشی پرمخاطره است که می‌تواند منجر به بروز مسمومیت قارچی شود. در این پژوهش امکان‌سنجی کاربرد سامانه بویایی ماشین بر پایه‌ی حسگرهای نیمه هادی اکسید فلزی به عنوان ابزاری غیر مخرب برای تفکیک قارچ‌های غیرخوراکی از قارچ‌های خوراکی مورد ارزیابی قرار گرفت. تحلیل مؤلفه‌های اصلی PCA، تحلیل تفکیک خطی LDA، تحلیل تفکیک خطی درجه ۲ QDA، ماشین بردار پشتیبان SVM و شبکه عصبی مصنوعی ANN روش‌هایی بودند که برای رسیدن به این هدف مورد استفاده قرار گرفتند. نتایج به‌دست آمده از تحلیل‌ها نشان داد که بهترین عملکرد در روش PCA در تفکیک ۵ نمونه قارچ خوراکی و غیرخوراکی با دقت ۹۱ درصدی بود. نتایج به دست آمده نشان داد که روش تحلیل QDA با دقت ۱۰۰ درصدی و عملکرد بهتری از روش LDA نمونه‌های قارچ را در سه دسته‌ی مختلف تفکیک کرد. در این میان، روش SVM از میان نمونه‌های قارچ خوراکی و قارچ غیرخوراکی تنها توانست قارچ *A. bisporus* را به صورت کامل و ۱۰۰ درصدی تشخیص دهد و عملکرد مناسبی در تفکیک سایر نمونه‌ها نداشت. روش ANN عملکرد مطلوبی در طبقه‌بندی نمونه‌ها داشت، به طوری که توانست نمونه‌های *A. bisporus*، *S. comptus* و *R. delica* را به صورت ۱۰۰ درصدی طبقه‌بندی کند. با توجه به نتایجی که در این پژوهش به دست آمد، می‌توان گفت دقت روش QDA در طبقه‌بندی انواع مختلف قارچ‌ها نسبت به سایر روش‌ها بالاتر بود. با توجه به عملکرد مناسب بویایی ماشین در تفکیک قارچ‌های خوراکی از قارچ‌های غیرخوراکی، به نظر می‌رسد کاربرد این فناوری روشی امیدبخش در تفکیک گونه‌های مختلف قارچ خواهد بود.

واژه‌های کلیدی: قارچ خوراکی، قارچ غیرخوراکی، بویایی ماشین، هوش مصنوعی.

ارجاع: غلامی پ.، نجات لرستانی ع. و عقیلی ناطق ن. ۱۴۰۲. تشخیص قارچ‌های خوراکی و غیرخوراکی با استفاده از بینی الکترونیکی و هوش مصنوعی. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۲۹: ۹۳-۱۰۴. <https://dx.doi.org/10.22034/JRMAM.2023.14334.661>

۱- دانش‌آموخته کارشناسی ارشد گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه.
۲- دانشیار گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه.
۳- استادیار گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی سنقر، دانشگاه رازی، کرمانشاه.
۴- دانشیار گروه گیاه‌پزشکی، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه.

* نویسنده مسئول: lorestani@razi.ac.ir

تاریخ پذیرش: ۱۴۰۲/۰۲/۳۰

تاریخ دریافت: ۱۴۰۱/۱۱/۲۸

اعتماد که امکان تعدیث فارچ‌های غیرحورایی از حورایی را توسط افراد عادی میسر سازد، بسیار راهگشا خواهد بود (Ghasemi-Varnamkhasti *et al.*, 2011a; Ghasemi-Varnamkhasti *et al.*, 2011b; Ghasemi-Varnamkhasti *et al.*, 2012; Loutfi *et al.*, 2015). کارخانجات مواد غذایی از روش‌هایی مانند گاز کروماتوگرافی GC برای تجزیه و تحلیل بو استفاده می‌کنند. این روش علاوه بر هزینه زیاد، زمان‌بر هم هست. لذا بسیاری از محققان به دنبال توسعه و ساخت دستگاه‌هایی هستند که با قیمت کم، دقت و سرعت بالا نسبت به حس بویایی انسان، اطلاعات بویایی را فراهم کنند. یک سامانه بویایی ماشینی می‌تواند ترکیب بودار را با تخمینی از غلظت آن و یا تعیین برخی خواص ذاتی آن تشخیص دهد. کاری که بینی انسان به سختی قادر به انجام آن است (Niyakothari & Zandi, 2013). استفاده از بویایی ماشینی از روش‌های نوینی است که می‌توان در سنجش کیفیت و سلامت مواد غذایی از آن استفاده کرد. بینی الکترونیکی یا حسگر بویایی از جمله ابزارهای مهم در صنعت غذاست که خواص فیزیکی شیمیایی مواد را به سیگنال‌های الکتریکی تبدیل می‌کند. استفاده از بینی الکترونیکی دارای مزیت‌های بسیاری مانند کاربری آسان، سرعت بالا و هزینه کم نسبت به روش‌های دیگر در زمینه سنجش کیفیت مواد غذایی است. این سامانه، توانایی شبیه‌سازی حس بویایی انسان را داشته و سعی دارد رد اثر بوی مواد را به خوبی تشخیص دهد. در واقع مجموعه‌ای از حسگرها، فرایندها و اطلاعات پردازش شده است که از سیگنال‌های الکتریکی استخراج شده‌اند (Ghasemi-Varnamkhasti *et al.*, 2011a; Ghasemi-Varnamkhasti *et al.*, 2011b; Ghasemi-Varnamkhasti *et al.*, 2012; Loutfi *et al.*, 2015). پژوهش‌های بسیاری برای طبقه‌بندی از سامانه بینی الکترونیک استفاده شده است. در پژوهشی برای تشخیص درجه رسیدگی توت‌فرنگی از بینی الکترونیکی استفاده شد. با استفاده از بینی الکترونیکی ترکیبات فرآر معطر موجود در توت‌فرنگی تشخیص داده شد و از تجزیه و تحلیل اجزای اصلی (PCA) و تجزیه و تحلیل تفکیک خطی (LDA) برای تشخیص الگوی آرایه حسگرها استفاده گردید (Aghili Nategh *et al.*, 2019a).

از زمان‌های گذشته، مصرف قارچ‌ها به عنوان یک ماده غذایی پرطرفدار در میان انسان‌ها رواج پیدا کرده است. مردم برخی از کشورها تمایل بیشتری به جمع‌آوری و مصرف قارچ‌های خودرو دارند (Polese, 2005). در ایران نیز برخی افراد قارچ‌های خودرو را جمع‌آوری و مصرف می‌کنند. با این حال، وجود قارچ‌های سمی و حتی مهلک در بین قارچ‌های خودرو، مصرف قارچ‌های خودرو را بسیار مخاطره‌آمیز می‌سازد (Wasser *et al.*, 2000; Mohammadi-Goltapeh & Pourjam, 2005). حدود ۱۴ هزار گونه قارچ آگاریک وجود دارد که برخی خوراکی و برخی غیرخوراکی یا سمی هستند (Kirk *et al.*, 2008). قارچ‌های کلاهک‌دار (Agarics)، گروه بزرگی از قارچ‌های Basidiomycota را تشکیل می‌دهند که به راسته Agaricales، زیربرده Agaricomycetidae و زیرشاخه Agaricomycotina تعلق دارند (Kirk *et al.*, 2008). قارچ‌های آگاریک از نظر اقتصادی، اجتماعی، زیست‌محیطی و پزشکی از اهمیت بالایی برخوردار هستند. برخی از قارچ‌های آگاریک با ریشه گیاه رابطه هم‌زیستی دارند، این قارچ‌ها باعث جذب بهتر مواد غذایی از خاک می‌شوند و در تغذیه گیاه و همچنین محافظت از ریشه گیاه نقش مهمی دارند (Deacon, 1997). برخی از گونه‌ها از جمله *Lentinus* و *Armillaria* سبب بیماری‌زایی در گیاهان می‌شوند، همچنین برخی از آن‌ها مصرف دارویی و خوراکی دارند (Miles & Chang, 2004). شناسایی قارچ‌های ماکروسکوپی فقط توسط افراد متخصص و طی فرایندی زمان‌بر، که ممکن است مستلزم بررسی توالی DNA قارچ باشد، امکان‌پذیر خواهد بود. در عین حال، تشخیص سمی بودن قارچ‌ها نیازمند استفاده از روش‌های آزمایشگاهی پرهزینه از جمله کروماتوگرافی مایع با عملکرد بالا HPLC است (Barbosa *et al.*, 2022). بدیهی است، استفاده از روش‌های بررسی حضور مواد سمی در قارچ‌ها به دلایلی از جمله وقت‌گیر بودن، پرهزینه بودن و در دسترس نبودن تجهیزات پیشرفته محدود است. این روش‌های آزمایشگاهی در عین حال، مخرب هستند و به کاربر متخصص جهت آماده‌سازی نمونه‌ها و تجزیه و تحلیل نتایج نیاز دارند (Shabani *et al.*, 2019b).

بینی الکترونیک

سامانه بینی الکترونیک بر اساس ۱۰ حسگر نیمه هادی اکسید فلزی (MOS) ساخته شده که در جدول ۱ آمده است. سامانه از محفظه حسگرها، محفظه نمونه، ریزپمپ، شیر سنولوئیدی، سامانه جمع‌آوری داده (با رابط USB)، منبع تغذیه، تمیزکننده هوای ورودی (کربن فعال) و رابط گرافیکی (LabVIEW 2014) تشکیل شده است. مراحل اصلی کار بینی الکترونیک در سه مرحله زمانی ۱- رسیدن به خط مبنا ۲- تزریق بوی نمونه به داخل محفظه حسگرها و ۳- پاک‌سازی محفظه حسگرهای تقسیم‌بندی شده و الگوی پاسخ حسگرها در طول این سه موقعیت زمانی به صورت تغییر ولتاژ در مقابل زمان ثبت می‌گردد. در مرحله اول که ۳۰۰ ثانیه طول می‌کشد هوای پاک‌سازی شده وارد محفظه حسگرها می‌شود و فضای حسگرها را پاک‌سازی می‌کند تا تغییرات ولتاژی حسگرها حالت پایدار بگیرد. در مرحله دوم بوی نمونه وارد محفظه حسگرها می‌شود، این مرحله ۳۰۰ ثانیه طول می‌کشد. در مرحله سوم هوای فیلتر شده وارد محفظه شده و پس از پاک‌سازی محفظه خارج می‌گردد و این مرحله نیز ۱۵۰ ثانیه به طول می‌انجامد. آزمون بویایی برای هر یک از نمونه‌های قارچ به صورت ۱۰ تکرار انجام گرفت (Aghili Nategh et al., 2019a). تصویر سامانه بینی الکترونیک در شکل ۲ آورده شده است.

همچنین برای تشخیص باقی مانده سم Acetamidrid در آلبالو در درجات مختلف رسیدگی نیز از بینی الکترونیکی استفاده شده است (Aghili Nategh et al., 2019a). در پژوهش‌های بسیاری برای طبقه‌بندی از سامانه بینی الکترونیک استفاده شده است. در مطالعه‌ای دیگر، برای طبقه‌بندی شراب‌های برنج از یک سامانه بویایی با ۱۲ حسگر استفاده کردند و پس از پردازش داده‌ها سامانه بویایی به عنوان یکی از ابزار خوب و قوی برای طبقه‌بندی و شناسایی معرفی شد (Wei et al., 2017). در این پژوهش، امکان استفاده از فناوری بینی الکترونیکی و هوش مصنوعی برای تفکیک قارچ‌های خوراکی و غیرخوراکی مورد ارزیابی قرار گرفته است.

مواد و روش‌ها

آزمایش‌های بویایی در آزمایشگاه خواص فیزیکی و مکانیکی محصولات کشاورزی و غذایی دانشگاه رازی کرمانشاه انجام شد.

تهیه نمونه‌های قارچ

نمونه‌های قارچی ضمن بازدید از طبیعت جمع‌آوری شدند. پس از جمع‌آوری، نمونه‌ها به آزمایشگاه منتقل شده و با استفاده از کلیدهای معتبر قارچ‌شناسی شناسایی شدند. در این مطالعه، پنج گونه قارچ شامل *Pleurotus*، *Pleurotus ostreatus*، *Agaricus bisporus*، *Russula delica* و *Suillellus comptus*، *eryngii* استفاده قرار گرفت (شکل ۱). در این میان، سه گونه نخست خوراکی و دو گونه *S. comptus* و *R. delica* غیرخوراکی بودند.

جدول ۱- حسگرهای به کار رفته در سامانه بویایی

شماره حسگر	حسگر	کاربرد
C1	MQ3	الکل و بنزین
C2	MQ9	متان، مونواکسید کربن و گاز طبیعی
C3	TGS822	حساسیت بالا به بخارهای حلال‌های آلی
C4	TGS813	حساسیت بالا به پروپان و بوتان
C5	TGS2602	آلاینده‌های هوا
C6	MQ135	بنزن، آمونیاک، دی اکسید کربن، مونواکسید کربن و الکل
C7	TGS2610	بوتان و گاز مایع
C8	MQ6	گاز طبیعی، گاز شهر، الکل، بخار پخت و مونواکسید کربن
C9	TGS2611	حساسیت بالا به متان




شکل ۱- نمونه‌های قارچ مورد استفاده در ارزیابی سامانه بینی الکترونیک

الف، *Pleurotus eryngii*، ب، *Agaricus bisporus*، ج، *Suillellus comptus*، د، *Pleurotus ostreatus*، ه، *Russula delicata*.



ب



الف

شکل ۲- الف) نمای داخلی سامانه بینی الکترونیک و ب) نمای کلی سامانه بینی الکترونیک در هنگام آزمایش

جدول ۱- حسگرهای به کار رفته در سامانه بویایی

کاربرد	حسگر	شماره حسگر
الکل و بنزین	MQ3	C1
متان، مونواکسید کربن و گاز طبیعی	MQ9	C2
حساسیت بالا به بخارهای حلال‌های آلی	TGS822	C3
حساسیت بالا به پروپان و بوتان	TGS813	C4
آلاینده‌های هوا	TGS2602	C5
بنزن، آمونیاک، دی اکسید کربن، مونواکسید کربن و الکل	MQ135	C6
بوتان و گاز مایع	TGS2610	C7
گاز طبیعی، گاز شهر، الکل، بخار پخت و مونواکسید کربن	MQ6	C8
حساسیت بالا به متان	TGS2611	C9
الکل، تولونن، اگزولین، عطر، دیگر بخارات آلی و الکل	TGS2620	C10

پیش پردازش داده‌ها

به منظور استخراج ویژگی‌ها باید داده‌های استخراج شده پیش‌پردازش شوند. به کمک پیش‌پردازش پاسخ حسگرها آشکارسازی شده و دقت در تحلیل و بررسی الگوهای تشخیص افزایش می‌یابد. به منظور افزایش کیفیت پاسخ حسگرها باید خط مبنا تصحیح شود. تصحیح خط مبنا به

سه روش کسری، نسبی و اختلافی انجام می‌شود. برای تصحیح خط حسگرهای نیمه هادی اکسید فلزی به کار برده شده در پژوهش حاضر از روش کسری استفاده شد که در معادله (۱) نشان داده شده است (Gutierrez-Osuna, 2002; Kiani et al., 2018). در این روش، خط مبنا $X_s(0)$ از پاسخ حسگر $X_s(t)$ کم می‌شود و بعد

در حل مسائل پیچیده و غیر خطی و شبیه‌سازی سامانه درک انسان را دارد (Tohidi, 2010).

نتایج و بحث

نمودار امتیاز تحلیل PCA برای سه دسته از قارچ‌ها در شکل ۳ نشان داده شده است. براساس نتایج به دست آمده از تحلیل PCA در نمودار ۳- الف برای ۵ نمونه قارچ خوراکی و غیرخوراکی (*P. ostreatus*، *A. bisporus*، *S. comptus eryngii* و *R. delica*)، مقدار دو مؤلفه اصلی PC-1 و PC-2 به ترتیب ۸۲ و ۹ درصد هستند که مقدار واریانس بین نمونه‌ها در مجموع ۹۱ درصد کل داده‌ها را توصیف می‌کند. مطابق با نمودار نشان داده شده، به غیر از *A. bisporus*، در بین سایر قارچ‌ها مقدار کمی هم‌پوشانی دیده می‌شود. براساس نتایج به دست آمده از تحلیل PCA در نمودار ۳- ب برای دو گونه قارچ غیرخوراکی (*S. comptus* و *R. delica*)، دو مؤلفه اصلی PC-1 و PC-2 به ترتیب ۵۴ و ۳۳ درصد هستند که مقدار واریانس بین نمونه‌ها در مجموع ۸۷ درصد کل داده‌ها را توصیف می‌کند. با توجه به این که میان هر دو نمونه قارچ غیرخوراکی مقدار کمی هم‌پوشانی دیده می‌شود. می‌توان گفت پاسخ حسگرها به هر دو نوع قارچ غیرخوراکی تا حدودی مشابه یکدیگر بوده است. نتایج حاصل از PCA برای سه گونه قارچ خوراکی (*P. ostreatus*، *A. bisporus*، *P. eryngii*) در نمودار ۳- ج، نمایان است. مطابق با نمودار نشان داده شده، دو مؤلفه اصلی PC-1 و PC-2 به ترتیب ۸۵ و ۸ درصد هستند که مقدار واریانس بین نمونه‌ها در مجموع ۹۳ درصد کل داده‌ها را توصیف می‌کند. با توجه به نمودار امتیاز میان هر سه نمونه تمایز مناسبی وجود دارد و نشان از پاسخ متفاوت حسگرها به این سه نمونه است که دلیل آن عدم تشابه ترکیبات فرآر متصاعد شده از نمونه‌ها است. نمودار بارگذاری تعیین‌کننده نقش هریک از حسگرها در ایجاد تفکیک بین نمونه‌ها است. بدین ترتیب می‌توان حسگر یا حسگرهایی که کمترین تمایز را بین نمونه‌ها ایجاد می‌کنند، حذف کرد و با این کار موجب کاهش پیچیدگی تحلیل داده و کاهش هزینه ساخت آرایه حسگری شد. نمودار بارگذاری برای هر سه دسته نمونه در شکل ۴ آورده شده است. مطابق با نمودار ۴- الف حسگر C1 بیشترین مقادیر ضریب بارگذاری را داشته و بنابراین بیشترین نقش را در تمایز بین قارچ‌های خوراکی

نتیجه بر خط مبنا تقسیم خواهد شد. پاسخ پردازش شده $(Y_s(t))$ مولفه‌ای بی بعد و نرمال شده خواهد بود. این پاسخ می‌تواند پاسخ حسگرهایی را که ذاتاً سطح پاسخ بالا یا پایینی دارند، جبران کند (Arshak *et al.*, 2004).

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

تحلیل داده‌ها

داده‌های پیش‌پردازش شده به روش‌های تحلیل مؤلفه‌های اصلی (Principal Component Analysis) PCA، تحلیل تفکیک خطی (Linear Discriminant Analysis) LDA، تحلیل تفکیک خطی درجه ۲ (Quadratic Discriminant Analysis) QDA، ماشین بردار پشتیبان (Support Vector Machine) SVM و شبکه عصبی مصنوعی (Artificial Neural Network) ANN با استفاده از نرم‌افزار Unscrambler 10.4 و MATLAB 2017 تحلیل شدند. تحلیل مؤلفه اصلی یک روش آماری است که از آن برای تبدیل مجموعه‌هایی از داده‌های به‌دست آمده دارای همبستگی به مجموعه‌هایی از متغیرهای غیر همبسته خطی که اجزای اصلی هستند، استفاده می‌کنند (Esteki *et al.*, 2017). تحلیل تفکیک خطی یک روش طبقه‌بندی با نظارت است که برای دسته‌بندی و طبقه‌بندی داده‌ها، طبقه‌ها را در نظر می‌گیرد و بر اساس تفاوت طبقه‌ها، ویژگی‌های مهم را استخراج می‌کند. هدف این روش این است که داده‌های مربوط به یک طبقه تا حد امکان به هم نزدیک و داده‌های طبقه‌های مختلف از هم دور باشند (Jamalizadeh *et al.*, 2019).

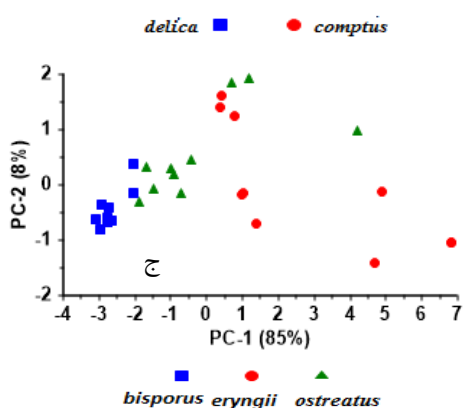


تحلیل تفکیک درجه دوم یکی از روش‌های آماری است که برای پیدا کردن ترکیب خطی و درجه دوم خصوصیتی که به بهترین صورت دو یا چند گروه از اشیاء را از هم جدا می‌کنند استفاده می‌شوند (Chinipardaz *et al.*, 2015).

ماشین بردار یکی از روش‌های یادگیری با نظارت است که از آن برای گروه‌بندی و برآورد تابع برازش داده‌ها استفاده می‌شود، به طوری که کمترین خطا در گروه‌بندی داده‌ها یا تابع برازش رخ می‌دهد (Safari Amiri *et al.*, 2018).



شبکه عصبی مصنوعی با الهام از سامانه عصبی زیستی به عنوان یک سامانه پردازش داده و مدل محاسباتی، سعی

پژوهش (Taheri-Garavand *et al.* (2020) به طبقه‌بندی هوشمند گوشت مرغ تازه از نوع منجمد یخ‌زدایی شده به کمک بویایی ماشین پرداختند. بر اساس نتایج روش PCA، سامانه بویایی عملکرد مناسبی برای بررسی تازگی گوشت مرغ داشت. همچنین نتایج نمودارهای رادار و بارگذاری نشان داد که بوی گوشت مرغ بیشترین کم‌ترین تأثیر را به ترتیب بر روی حسگرهای MQ136 و TGS822 داشته است.


و غیر خوراکی ایفا می‌کند. حسگر C8 کمترین تأثیر را در تمایز بین قارچ‌های غیر خوراکی و خوراکی دارد. مطابق با نمودار ۴-ب حسگرهای C1 و C2 بیشترین مقادیر ضریب بارگذاری دارند. حسگر C7 یا TGS2610 کمترین تأثیر را در تمایز بین قارچ‌های غیر خوراکی دارد. مطابق با نمودار ۴-ج، حسگر C7 بیشترین مقادیر ضریب بارگذاری را داشته و بنابراین بیشترین نقش را در تمایز بین قارچ‌های خوراکی ایفا می‌کند. حسگر C10 کمترین ضریب بارگذاری و تأثیر در تمایز بین نمونه‌ها را داشت. در یک



شکل ۳- نمودار امتیاز تحلیل PCA برای: (الف) پنج نمونه از قارچ‌های خوراکی و غیر خوراکی، (ب) دو نمونه قارچ غیر خوراکی، (ج) سه نمونه قارچ خوراکی



شکل ۴- نمودار بارگذاری، تحلیل PCA برای: (الف) پنج گونه قارچ





خوراکی و غیر خوراکی، (ب) دو گونه قارچ غیر خوراکی، (ج) سه گونه قارچ خوراکی


نتایج به دست آمده از ماتریس اغتشاش پنج نمونه قارچ خوراکی و غیر خوراکی بیان گر آن است که به غیر از *P. ostreatus* در سایر نمونه‌ها از تعداد ۱۰ نمونه، تعداد کل نمونه‌ها به درستی تشخیص داده شده‌اند. در قارچ *P. ostreatus* از تعداد ۱۰ نمونه، تعداد ۸ نمونه به درستی تشخیص داده شده‌اند (جدول ۲). همچنین نتایج به دست آمده از ماتریس اغتشاش دو نمونه قارچ غیر خوراکی بیان می‌کند که در قارچ‌های غیر خوراکی از تعداد ۱۰ نمونه تعداد کل نمونه‌ها به درستی و با دقت ۱۰۰ درصدی تشخیص داده شده‌اند (جدول ۳). همچنین نتایج به دست آمده از ماتریس اغتشاش در سه نمونه قارچ خوراکی (جدول ۴) بیان می‌کند که در قارچ‌های خوراکی دو قارچ *A. bisporus* و *P. eryngii* از تعداد ۱۰ نمونه تعداد کل نمونه‌ها به درستی تشخیص داده شده‌اند و دقت کلی تفکیک سه نمونه ۹۶/۶۷ درصد بود. مطابق با نتایج به دست آمده از روش LDA می‌توان گفت روش LDA روشی با عملکرد مناسب و دقت تشخیص بالا در تشخیص هر سه دسته از نمونه‌های قارچ است.

Makarichian et al., (2022) به کمک LDA، ANN و SVM به طبقه‌بندی قارچ‌های آلوده و سالم در طی ۲۸ روز انبارداری پرداختند که نتایج نشان داد LDA ابزار مناسب‌تری برای طبقه‌بندی بود.

نتایج LDA

نمودار LDA برای سیگنال‌های حاصل از بینی الکترونیک در تشخیص سه دسته از نمونه‌های قارچ در شکل ۵ نشان داده شده است. براساس نمودار ۵-الف، نتایج دقت LDA تشخیص ۹۶ درصدی را برای ۵ نمونه قارچ خوراکی و غیر خوراکی نشان می‌دهد. همان‌گونه که در نمودار ۵-الف نمایان است مقدار کمی از هم‌پوشانی در بین نمونه‌های قارچ خوراکی دکمه‌ای و صدفی وجود دارد. اما سایر نمونه‌ها به صورت کامل از هم تفکیک شده‌اند. نمودار ۵-ب نتایج LDA را برای نمونه‌های قارچ غیر خوراکی نشان می‌دهد. مطابق با نتایج نشان داده شده هر دو نوع قارچ غیر خوراکی به صورت کامل از یکدیگر تفکیک شده‌اند. نتایج LDA دقت تشخیص ۱۰۰ درصدی را برای هر دو نمونه قارچ غیر خوراکی نشان می‌دهد. نمودار ۵-ج نتایج LDA را برای نمونه‌های قارچ خوراکی نشان می‌دهد. مطابق با نتایج نشان داده شده هر سه نوع قارچ خوراکی به صورت کامل از یکدیگر تفکیک شده‌اند. نتایج LDA دقت تشخیص ۹۶/۶۷ درصدی را برای نمونه‌های خوراکی نشان می‌دهد. نتایج به دست آمده از نمودارهای LDA نشان می‌دهد که روش به کار برده شده، شاخص مناسب و قابل قبولی برای طبقه‌بندی هر سه دسته از نمونه‌های قارچی است. همچنین نتایج LDA به صورت ماتریس اغتشاش نیز در جداول ۲ تا ۴ آورده شده است.





شکل ۵- نمودار LDA برای (الف) پنج نمونه قارچ‌های خوراکی و غیر خوراکی (ب) دو نمونه قارچ غیر خوراکی (ج) سه نمونه قارچ خوراکی

جدول ۲- ماتریس اغتشاش LDA برای پنج نمونه قارچ‌های

خوراکی و غیر خوراکی					
نمونه	۱	۲	۳	۴	۵
۱	۱۰	۰	۱	۰	۰
۲	۰	۱۰	۰	۰	۰
۳	۰	۰	۸	۰	۰
۴	۰	۰	۰	۱۰	۰
۵	۰	۰	۱	۰	۱۰

جدول ۳- ماتریس اغتشاش LDA برای دو نمونه قارچ

غیر خوراکی		
نمونه	۱	۲
۱	۱۰	۰
۲	۰	۱۰

جدول ۴- ماتریس اغتشاش LDA برای سه نمونه قارچ خوراکی

نمونه	۱	۲	۳
۱	۱۰	۰	۱
۲	۰	۱۰	۰
۳	۰	۰	۹

نتایج QDA

شکل ۶ نتایج حاصل از تحلیل QDA را برای سه دسته از قارچ‌ها نشان داده است. مطابق با نمودار ۶-الف، QDA توانسته است در تفکیک پنج نمونه قارچ خوراکی و غیر خوراکی عملکرد ۱۰۰ درصدی داشته باشد. همچنین مطابق نمودار ۶-ب، روش QDA توانسته است در تفکیک نمونه‌های قارچ غیر خوراکی نیز عملکرد مناسب داشته باشد و نمونه‌ها را با دقت ۱۰۰ درصدی و به صورت کامل از هم تفکیک کرده و تشخیص دهد. عملکرد خوب و مناسب QDA در تفکیک نمونه‌های قارچ خوراکی نیز نمایان است. همان‌طور که در نمودار ۶-ج آمده است، QDA توانسته نمونه‌های قارچ خوراکی را نیز به صورت کامل و با دقت ۱۰۰ درصدی از یکدیگر متمایز کند. مطابق با نتایج ماتریس اغتشاش در جدول ۵، در هر پنج

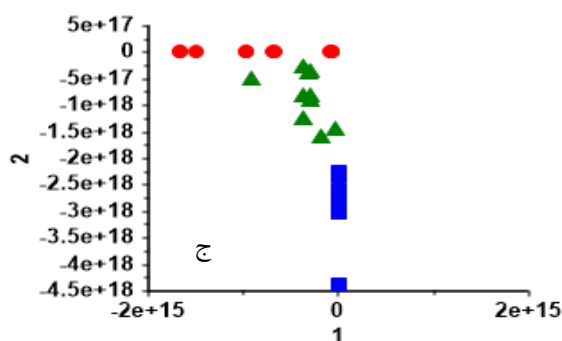
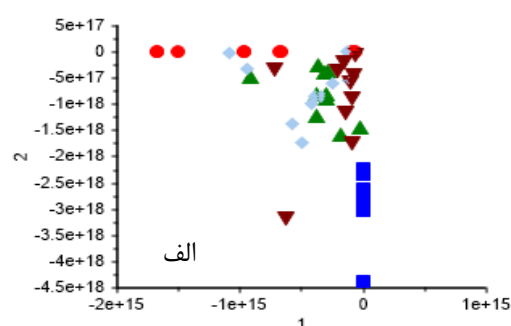
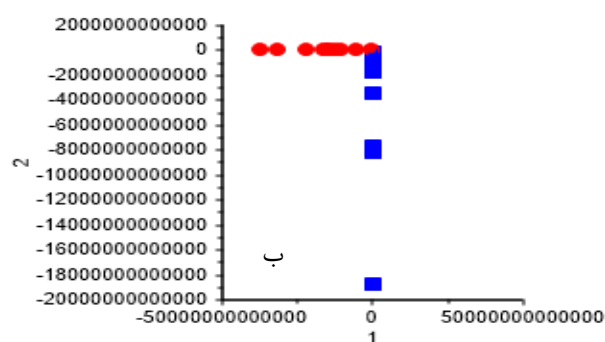
نمونه قارچ خوراکی و غیر خوراکی این روش توانسته است کل نمونه‌ها را به صورت صحیح و ۱۰۰ درصدی تشخیص دهد. عملکرد مناسب روش QDA در نمونه‌های قارچ غیر خوراکی که در جدول ۶ آورده شده است نیز تکرار شده و این روش توانسته است در تفکیک و تشخیص نمونه‌های قارچ غیر خوراکی نیز عملکرد ۱۰۰ درصدی داشته باشد. مطابق با جدول ۷ روش QDA توانسته است در تشخیص نمونه‌های قارچ خوراکی نیز عملکرد مناسبی از خود نشان دهد. به طوری که در هر دو تیمار از هر ده نمونه تعداد کل آن‌ها را به درستی تشخیص داده است و عملکرد ۱۰۰ درصدی داشته است. به طور کلی مطابق با نتایج به دست آمده از QDA می‌توان گفت این روش عملکرد مناسب و قابل قبولی در تفکیک و تشخیص سه دسته از نمونه‌های قارچ دارد. در یک مطالعه برای طبقه‌بندی خیار از تحلیل تفکیک درجه دوم QDA استفاده شد. براساس نتایج، دقت طبقه‌بندی با این روش برابر ۹۳/۱ درصد به دست آمد (Khairaliipour & Parma, 2015).

نتایج SVM

نتایج حاصل از تحلیل SVM در شکل ۷ نشان داده شده است. مطابق با نمودار ۷-الف روش SVM برای پنج نمونه قارچ خوراکی و غیر خوراکی (*P. ostreatus*, *A. bisporus*, *P. eryngii*, *S. comptus* و *R. delica*) عملکرد مناسبی نداشته و تنها ۶۰ درصد از نمونه‌ها را به درستی تشخیص داده است. نمودار ۷-ب عملکرد SVM را برای نمونه‌های قارچ غیر خوراکی (*R. delica* و *S. comptus*) نشان داده است. قدرت تشخیص SVM برای این دسته از نمونه‌های قارچ غیر خوراکی ۸۰ درصد بوده است. مطابق با نمودار ۷-ج قدرت تشخیص و شناسایی نمونه‌های قارچ خوراکی (*P. ostreatus*, *P. eryngii*) توسط روش SVM، ۵۶/۶۷ درصد بوده که نشان از عملکرد ضعیف

تشخیص قارچ *A.bisporus* عملکرد درستی از خود نشان داده است و از تعداد ۱۰ نمونه کل نمونه‌ها را با دقت ۱۰۰ درصدی تشخیص داده است در حالی که از تعداد ده قارچ *P.ostreatus* و *P. eryngii* پنج عدد قارچ را به درستی و پنج عدد قارچ را به صورت نادرست تشخیص داده است. به صورت کلی می‌توان گفت روش SVM در مقایسه با سایر روش‌ها عملکرد مناسبی در تشخیص نمونه‌های قارچ در هیچ یک از دسته‌ها نداشته است. پژوهش‌های مشابه نیز به دقت کمتر روش SVM در طبقه‌بندی محصولات کشاورزی و توانایی پایین آن اشاره نموده‌اند که دلیل آن ساختار این الگوریتم است. (Gholami *et al.* (2023) با بررسی کیفیت قارچ در طی ۲۸ روز انبارداری به کمک بویایی ماشین نشان دادند که دقت روش SVM نسبت به روش ANN برای طبقه‌بندی قارچ‌ها کمتر است.

روش SVM در تشخیص نمونه‌های قارچ خوراکی است. مطابق با نتایج ماتریس اغتشاش SVM در جدول ۸، از میان نمونه‌های قارچ خوراکی و قارچ غیرخوراکی، روش SVM توانسته است قارچ *A.bisporus* را به صورت کامل و ۱۰۰ درصدی تشخیص دهد در حالی که در تشخیص سایر نمونه‌ها عملکرد مناسبی نداشته است. جدول ۹ ماتریس اغتشاش SVM را برای نمونه‌های قارچ غیرخوراکی نشان می‌دهد. مطابق با نتایج جدول ۹ روش SVM هیچ یک از نمونه‌های قارچ غیرخوراکی را به صورت ۱۰۰ درصدی تشخیص نداده و عملکرد آن در هر دو قارچ غیرخوراکی یکسان بوده است به نحوی که از تعداد ۱۰ نمونه قارچ، تعداد ۹ نمونه را به درستی تشخیص داده است. در جدول ۱۰ نتایج به دست آمده از ماتریس اغتشاش SVM برای نمونه‌های قارچ خوراکی نشان داده شده است. مطابق با نتایج به دست آمده روش SVM در



شکل ۶- نمودار QDA برای (الف) پنج نمونه قارچ‌های خوراکی و غیرخوراکی (ب) دو نمونه قارچ غیرخوراکی (ج) سه نمونه قارچ خوراکی

جدول ۵- ماتریس اغتشاش QDA برای پنج نمونه قارچ‌های خوراکی و غیرخوراکی

نمونه	۱	۲	۳	۴	۵
۱	۱۰	۰	۰	۰	۰
۲	۰	۱۰	۰	۰	۰
۳	۰	۰	۱۰	۰	۰
۴	۰	۰	۰	۱۰	۰
۵	۰	۰	۰	۰	۱۰

جدول ۶- ماتریس اغتشاش QDA برای دو نمونه قارچ غیرخوراکی

نمونه	۱	۲
۱	۱۰	۰
۲	۰	۱۰

جدول ۷- ماتریس اغتشاش QDA برای سه نمونه قارچ

نمونه	خوراکی		
	۱	۲	۳
۱	۱۰	۰	۰
۲	۰	۱۰	۰
۳	۰	۰	۱۰

جدول ۹- ماتریس اغتشاش SVM برای دو نمونه قارچ


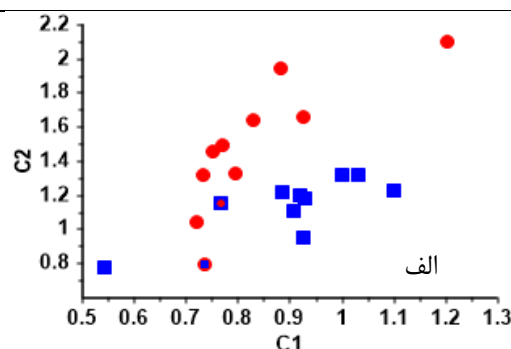

نمونه	غیرخوراکی	
	۱	۲
۱	۹	۱
۲	۱	۹

جدول ۸- ماتریس اغتشاش SVM برای پنج نمونه قارچ‌های

نمونه	خوراکی و غیرخوراکی				
	۱	۲	۳	۴	۵
۱	۱۰	۰	۷	۰	۰
۲	۰	۱	۰	۰	۰
۳	۰	۵	۲	۱	۱
۴	۰	۴	۸	۱	۰
۵	۰	۰	۰	۱	۹

جدول ۱۰- ماتریس اغتشاش SVM برای سه نمونه قارچ

نمونه	خوراکی		
	۱	۲	۳
۱	۱۰	۰	۷
۲	۰	۵	۱
۳	۰	۵	۲



شکل ۷- نمودار SVM برای (الف) پنج نمونه قارچ خوراکی و غیرخوراکی (ب) دو نمونه قارچ غیرخوراکی (ج) سه نمونه قارچ خوراکی

نتایج ANN

جدول ۱۱ ماتریس اغتشاش ANN را برای نمونه‌های قارچ خوراکی و غیرخوراکی نشان می‌دهد. مطابق با نتایج جدول، روش ANN توانسته است نمونه‌های (A. *R. delica* و *S. comptus bisporus*) را به صورت ۱۰۰ درصدی طبقه‌بندی کند. همچنین در طبقه‌بندی دو قارچ دیگر نیز عملکرد مناسبی داشته و حدود ۹۰ درصد نمونه‌ها را به درستی طبقه‌بندی کرده است. در این روش وضعیت آموزش شبکه با تعداد تکرارهای آزمایش برای

ایجاد شبکه مناسب شناخته شد و پس از اجرای مدل شبکه، بهترین جواب در تکرار ۸ حاصل شد و اجرای شبکه متوقف گردید. در تکرار ۸ بهترین عملکرد اعتبار سنجی با میانگین مربعات خطای (MSE) ۰/۰۵۵ حاصل شد. همچنین ضریب رگرسیون (r) آموزش، اعتبارسنجی، آزمایش و در آخر ضریب رگرسیون کل (r) برای انواع مختلف قارچ خوراکی و غیرخوراکی برای داده‌های بویایی برابر با ۰/۸۹۹ به دست آمد. ساختار شبکه‌ی عصبی در این دسته از نمونه‌ها ۵، ۸ و ۱۰ به دست آمد. جدول ۱۲

۱۰	۰	۰	۰	۰	۵
جدول ۱۲- ماتریس اغتشاش ANN برای دو نمونه قارچ غیرخوراکی					
	نمونه	۱	۲		
۱	۰	۱۰	۰		
۲	۰	۰	۱۰		

جدول ۱۳- ماتریس اغتشاش ANN برای سه نمونه قارچ خوراکی					
	نمونه	۱	۲	۳	
۱	۰	۱۰	۰	۰	
۲	۰	۰	۱۰	۰	
۳	۰	۰	۰	۱۰	

نتیجه‌گیری

در این پژوهش از یک سامانه‌ی بویایی ماشین بر پایه‌ی ده حسگر نیمه هادی اکسید فلزی (MOS) برای تفکیک قارچ خوراکی و غیرخوراکی استفاده شد. تحلیل مؤلفه‌های اصلی (PCA)، تحلیل تفکیک خطی (LDA)، تحلیل تفکیک درجه دوم (QDA)، ماشین بردار پشتیبان (C-SVM) و شبکه عصبی مصنوعی (ANN) برای تفکیک قارچ‌های خوراکی و غیرخوراکی مورد استفاده قرار گرفتند. روش تحلیل تفکیک درجه دوم بهترین نوع تحلیل و ماشین بردار پشتیبان ضعیف‌ترین نوع تفکیک را به خود اختصاص دادند. همچنین روش‌های LDA، PCA و ANN در تفکیک قارچ‌های غیرخوراکی و خوراکی عملکرد مناسبی از خود نشان دادند. برای تفکیک قارچ‌های غیرخوراکی و خوراکی از همدیگر بر اساس تحلیل PCA، حسگر C1 بیشترین نقش را در تمایز بین پنج نمونه قارچ‌های خوراکی و غیرخوراکی، در تشخیص و تمایز میان نمونه‌های قارچ غیرخوراکی با هم حسگرهای C1، C2 و در تمایز بین قارچ‌های خوراکی حسگر C10 بیشترین نقش را ایفا کردند.

منابع

Aghili Nategh, N., Anwar, A. & Dalvand, M. J. (2019a). Detection of estamipride toxin residues in cherries at different levels of processing with the help of electronic nose. *Journal of Agricultural Engineering*, 43: 87-105 (In Persian).

ماتریس اغتشاش ANN را برای نمونه‌های قارچ غیرخوراکی نشان می‌دهد. مطابق نتایج ماتریس اغتشاش روش ANN توانسته است در طبقه‌بندی هر دو نوع قارچ غیرخوراکی عملکرد مناسب و ۱۰۰ درصدی داشته باشد. در این تحلیل، بهترین عملکرد مدل شبکه عصبی پس از اجرا در تکرار ۶ به دست آمد و پس از رسیدن به دقت مطلوب اجرای شبکه متوقف شد. بهترین عملکرد اعتبارسنجی در تکرار ۶ با MSE ۰/۰۰۹ حاصل شد. ضریب رگرسیون کل (r) برای دو نمونه قارچ غیرخوراکی (*R. delica* و *S. comptus*) برابر با ۰/۹۷۸ به دست آمد. ورودی ساختار شبکه‌ی عصبی در این دسته از نمونه‌ها ۱۰ و تعداد خروجی ۳ است. تعداد نرون‌های مخفی در این مدل ۶ نرون است. در جدول ۱۳ نتایج حاصل از ماتریس اغتشاش ANN برای نمونه‌های قارچ خوراکی نشان داده شده است. مطابق با نتایج به دست آمده، روش ANN توانسته است هر سه نوع قارچ خوراکی را به صورت ۱۰۰ درصدی طبقه‌بندی کند. پس از اجرای مدل شبکه، بهترین جواب در تکرار ۳ به دست آمد و بهترین عملکرد اعتبارسنجی با میانگین مربعات خطای ۰/۰۱۲ حاصل شد. وضعیت آموزش شبکه با تعداد تکرارهای آزمایش برای ایجاد شبکه مناسب گزارش شد و ضریب رگرسیون کل (r) برای انواع مختلف قارچ‌های خوراکی برابر با ۰/۹۸۱ به دست آمد. ورودی ساختار شبکه‌ی عصبی در این دسته از نمونه‌ها ۲-۸-۱۰ است. به طور کلی روش ANN به عنوان روشی مناسب در طبقه‌بندی نمونه‌های مختلف قارچ شناخته شد. که علت آن می‌تواند غیر خطی بودن این الگوریتم باشد. در تحقیقی برای تشخیص درجه‌های رسیدن شاتوت و توت سفید، روش ANN نسبت به روش‌های PCA و LDA طبقه‌بندی بهتری نشان داد، به طوری که با دقت ۱۰۰ درصد نمونه‌های شاتوت و با دقت ۸۸/۳ درصد نمونه‌های توت سفید را طبقه‌بندی کرد (Aghili Nategh et al., 2019b).

جدول ۱۱- ماتریس اغتشاش ANN برای پنج نمونه قارچ‌های

خوراکی و غیرخوراکی						
	نمونه	۱	۲	۳	۴	۵
۱	۰	۱۰	۰	۰	۰	۵
۲	۰	۰	۹	۰	۰	۰
۳	۰	۰	۱	۹	۰	۰
۴	۰	۰	۰	۱	۱۰	۰

- Aghili Nategh, N., Anwar, A. & Dalvand, M. J. (2019b). Determining the degree of ripeness of strawberries with the help of an electronic nose. *Agricultural Machinery Mechanics Research*, 9: 71-80 (In Persian).
- Arshak, K., Moore, E., Lyons, G., Harris, J. & Clifford, S. (2004). A review of gas sensors employed in electronic nose applications. *Sensor review*, 24: 181-198.
- Barbosa, I., Domingues, C., Ramos, F. & Barbosa, R. M. (2022). Identification and quantification of α - and β -amanitin in wild mushrooms by HPLC-UV-EC and HPLC-DAD-MS detection. bioRxiv.
- Chinipardaz, R., Rekabdar, Q. & Yousefi Hajiabad, R. (2015). Studying the human development of countries using mixed audit analysis methods. *Quarterly Journal of Economic Studies*, 3: 5-20 (In Persian).
- Deacon, J. W. (1997). *Modern mycology*. Blackwell Science Oxford, pp. 303.

- Loutfi, A., Coradeschi, S., Mani, G. K., Shankar, P. & Rayappan, J. B. B. (2015). Electronic noses for food quality: A review. *Journal of Food Engineering* 144: 103-111.
- Makarichian, A., Chayjan, R. A., Ahmadi, E., Zafari, D. (2022). Early detection and classification of fungal infection in garlic (*A. sativum*) using electronic nose. *Comput Electron Agric.* <https://doi.org/10.1016/j.compag.2021.106575>
- Mohammadi-Goltapeh, E. & Pourjam, E. (2005). Principles of Mushroom Cultivation. Tarbiat Modarres University Press, Tehran, pp. 626.
- Miles, P. G., & Chang, S. T. (2004). *Mushrooms: cultivation, nutritional value, medicinal effect, and environmental impact*. CRC press.
- Niyakothari, M. & Zandi, M. (2013). *Electronic smell and taste systems in food industry*. Aayizh pp. 176 (In Persian).
- Polese, J. M. (2005). *The Pocket Guide to Mushrooms*. Konemann Publisher. 381 pp.
- Safari Amiri, Z., Ghasemi Varnamkhashidi, M., Tohidi, M., Mohtasbi, S.S. & Dowlati, M. (2018). Using the olfactory machine system in order to detect fraud in cumin. *Innovative Food Technologies*, 5: 527-541 (In Persian).
- Shabani, P., Yazidi, Z., Ghasemi-Varnamkhashidi, M., Tawhidi, M. & Rizi, S. (2017). Smell machine system, an effective approach to detect fraud in rose water. *Innovative Food Technologies*, 6: 78-89 (In Persian).
- Taheri-Garavand, A., Mirzaee-Ghaleh, E. & Ayari, F. (2020). Intelligent Classification of Fresh Chicken Meat from Frozen-Thawed Using Olfactory Machine. *Food Technology and Nutrition*, 17: 13-22 (In Persian).
- Tohidi, M. (2010). *Simulation of rough rice drying using artificial neural networks*. M. Sc. Thesis, Isfahan University of Technology. Iran.
- Wasser, S.P., Sokolov, D., Reshetnikov, S.V. & Timor-Tismenetsky, M. (2000). Dietary supplements from medicinal mushrooms: diversity of types and variety of regulations. *International journal of medicinal mushrooms* 2.
- Wei, Z., Xiao, X., Wang, J. & Wang, H. (2017). Identification of the rice wines with different marked ages by electronic nose coupled with smartphone and cloud storage platform. *Sensors* 17: 2500.
- Esteki, M., Farajmand, B., Kolahderazi, Y. & Simal-Gandara, J. (2017). Chromatographic fingerprinting with multivariate data analysis for detection and quantification of apricot kernel in almond powder. *Food Analytical Methods*, 10: 3312-3320.
- Gholami, R., Aghili Nategh, N., Rabbani, H., (2023). Evaluation the effects of temperature and packaging conditions on the quality of button mushroom during storage using e-nose system. *Journal of Food Science and Technology*, 60(4): 1355-1366.
- Ghasemi-Varnamkhashidi, M., Mohtasebi, S., Rodriguez-Mendez, M., Lozano, J., Razavi, S. & Ahmadi, H. (2011a). Potential application of electronic nose technology in brewery. *Trends in Food Science & Technology*, 22: 165-174.
- Ghasemi-Varnamkhashidi, M., Mohtasebi, S.S., Siadat, M., Lozano, J., Ahmadi, H., Razavi, S.H. & Dicko, A. (2011b). Aging fingerprint characterization of beer using electronic nose. *Sensors and Actuators, B: Chemical*, 159: 51-59.
- Ghasemi-Varnamkhashidi, M., Mohtasebi, S.S., Siadat, M., Razavi, S.H., Ahmadi, 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: 236-240.
- Gutierrez-Osuna, R. (2002). *Signal conditioning and pre-processing Handbook of Machine Olfaction: Electronic Nose Technology*, ed TC Pearce, SS Schiffman, HT Nagle and JW Gardner. Weinheim, Germany: Wiley-VCH.
- Jamalizadeh, F., Ghasemi Varnamkhashidi, M., Ghasemi Nafchi, M., Tohidi, M. & Dowlati, M. (2019). Implementation of an olfactory machine system for classifying different types of black pepper based on geographical origin and detecting fraud in Indian black pepper. *Journal of Food Science and Industry Research*, 16: 479-491(In Persian).
- Khairaliipour, K. & Parma, A. (2015). Using linear (LDA) and quadratic (QDA) discriminant analysis to classify shape features of cucumber fruit, *Proceedings of the Eighth National Conference on Agricultural Research Findings*.
- Kiani, S., Minaei, S. & Ghasemi-Varnamkhashidi, M. (2018). Real-time aroma monitoring of mint (*Mentha spicata* L.) leaves during the drying process using electronic nose system. *Measurement*, 124: 447-452.
- Kirk, P.M., Cannon, P.F., Minter, D.W. & Stalpers, J.A. (2008). *Dictionary of the Fungi*. Cab International, Wallingford, UK, pp. 771.