



Elektronik Burun ve Makine Öğrenmesi Yöntemleri Kullanılarak Gıda Aromalarının Sınıflandırılması

Classification of Food Flavors using Electronic Nose and Machine Learning Methods

¹İlyas ÖZER , ²Kutlucan GÖRÜR , ^{3*}Onursal ÇETİN , ⁴Feyzullah TEMURTAŞ 

^{1,2,3,4}Bandırma Onyedil Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, 10200, Bandırma/Balıkesir, Türkiye

¹iozer@bandirma.edu.tr, ²kgorur@bandirma.edu.tr

³ocetin@bandirma.edu.tr, ⁴ftemurtas@bandirma.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 15 December 2023

Accepted : 29 January 2024

Keywords:

Electronic Nose, Food Flavor, Odor, Machine Learning

ABSTRACT

The aim of this study is to determine the classes of flavors from chemical odor data obtained from different food flavors using electronic nose and machine learning methods. The relationship between volatile and non-volatile components in food flavors has been intensively researched. Normalized analytical protocols are applied to monitor the occurrence of regulated chemicals in processed foods. Although these methods are robust, they involve highly specialized instrumentation and time-consuming and expensive procedures. The electronic nose is a cost-effective and powerful electronic device that can make rapid measurements to distinguish food flavors. Since the molecules responsible for aromatic compounds released during food processing can be detected by the human nose, it may be possible to use electronic nose to detect changes in processed food products. In this research study, the calculated classification outcomes were estimated above $\geq 90.00\%$ accuracy with sensitivity (≥ 90.00) and specificity (≥ 90.00) scores.

© 2024 Bandırma Onyedil Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 15 Aralık 2023

Kabul : 29 Ocak 2024

Anahtar Kelimeler:

Elektronik Burun, Gıda Aroması, Koku, Makine Öğrenmesi

ÖZET

Bu çalışmanın amacı, elektronik burun ve makine öğrenimi yöntemlerini kullanarak farklı gıda aromalarından elde edilen kimyasal koku verilerinden aromalara ait sınıfların belirlenmesidir. Gıda aromaları içinde bulunan uçucu ve uçucu olmayan bileşenler arasındaki ilişki yoğun bir şekilde araştırılmaktadır. İşlenmiş gıdalarda düzenlenmiş kimyasal oluşumunu izlemek için normalleştirilmiş analitik protokoller uygulanır. Bu yöntemler sağlam olmasına karşın, son derece uzmanlaşmış enstrümantasyon, zaman alıcı ve pahalı prosedürler içerir. Elektronik burun, gıda tatlarını ayırt etmek için hızlı ölçümler yapabilen, uygun maliyetli ve güçlü bir elektronik cihazdır. Gıda işleme sırasında açığa çıkan aromatik bileşiklerinden sorumlu moleküller insan burnu tarafından tanınabildiğinden, işlenmiş gıda ürünlerinde meydana gelen değişiklikleri tespit etmek için elektronik burun kullanmak mümkündür. Bu araştırma çalışmasında hesaplanan sınıflandırma sonuçları, duyarlılık ($\geq 90.00\%$) ve özgüllük ($\geq 90.00\%$) ile $\geq 90.00\%$ 'in üzerinde doğrulukla tahmin edilmiştir.

© 2024 Bandırma Onyedil Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

ORCID ID: ¹0000-0003-2112-5497

²0000-0003-3578-0150

³0000-0001-5220-3959

⁴0000-0002-3158-4032

1. GİRİŞ

Yiyecek ürünlerin kalitesi, yiyeceğin lezzetini/aromasını ve güvenliğini etkiler. Test kağıdı, siklotron veya kromatografi gibi geleneksel tespit yöntemlerinin doğruluk, tespit aralığı, zaman tüketimi, taşınabilirlik ve maliyet açısından bazı sınırları olduğu bilinmektedir [1]. Yapay koku sistemi (Artificial Olfactory System/AOS) ve elektronik burun (Electronic Nose/E-Nose), kısa algılama döngüsü, yüksek hassasiyet ve karmaşık ön işleme gerekmemesi gibi avantajlara sahip olan hayvan ve insan koku sensörlerini simüle ederek gıda kalitesini algılayabilir ve tanımlayabilir. E-Nose veya AOS, kokuyu tespit etmek ve tanımlamak için hayvanın veya insanın koku algısı mekanizmasını simüle eder [1, 2]. Gıda kalitesini tespit etmek için potansiyel olarak iyi bir yöntem olabilir. Biyoteknolojik bir ölçüm yöntemi olarak E-Nose ve AOS, temel olarak insan koku alma sistemi sürecini simüle ederek sinyal tanıma ve işlemeyi gerçekleştirir. Sensör dizisi, insan koku alma reseptörlerini taklit edecek şekilde tasarlanırken, sensörler ve gazlar arasındaki elektrokimyasal geri besleme sinyalleri, insan koku alma sistemindeki enzim basamaklı reaksiyonları olarak görülmektedir. E-Nose ve AOS, çevresel izleme, gıda endüstrisi (aroma sınıflandırma ve gıda tazeliği), kimya endüstrisi ve tıbbi üretim gibi çeşitli alanlarda yaygın olarak kullanılmaktadır [1-4].


E-Nose ve AOS'un sensör dizisi, çeşitli kokular ve aromalar için farklı örüntüler gösterir ve bunlar, kokuların durumunu örüntü tanıma algoritmalarıyla tanımlamak için kullanılabilir. Aroma sınıflandırma ve gıda güvenliği tespitinde Temel Bileşenler Analizi (Principal Component Analysis/PCA), Doğrusal Diskriminant Analizi (Linear Discriminant Analysis/LDA), K-En Yakın Komşu (K-Nearest Neighbor/KNN), Geri Yayılan Yapay Sinir Ağı/ Çok Katmanlı Sinir Ağı (Backpropagation – Artificial Neural Network veya /BP-ANN/ Multilayer Neural Network), öğrenme vektör nicelmesi (Learning Vector Quantization/LVQ) gibi birçok yöntem kullanılmaktadır. Bununla beraber kendi kendini organize eden harita (Self-Organizing Map/SOM), olasılıksal sinir ağı (Probabilistic Neural Network/PNN) ve diğer makine öğrenmesi yöntemleri de E-Nose ve AOS ile birlikte gıda/aroma ve hassasiyet/sınıflandırma değerlendirmesinde uygulanmıştır [1-4]. Bu çalışmaların son yıllarda literatürde önem kazandığı ve giderek arttığı görülmektedir.

Makine öğrenimi modeli (Machine Learning/ML), E-Nose ve AOS'un temeli olarak görülebilir. ML son yıllarda gıda kalitesi değerlendirmesinde yaygın olarak uygulanmaktadır [1]. Meyvelerdeki nem içeriğindeki değişiklikleri izlemek için invazif olmayan bir ML odaklı teknik, Ren ve arkadaşları tarafından önerilmiştir [5]. Matteo ve ark. farklı kahve gruplarını sınıflandırmak için PCA ve çok katmanlı algılayıcılara sahip yeni bir E-Nose yaklaşımı kullanmıştır [6]. Palaş ve ark. su numunelerinin kategorisini belirlemek için çeşitli sinir ağı sınıflandırıcılarının paralel kombinasyonundan oluşan bir sistem geliştirdiklerini rapor etmişlerdir [7]. Antony ve ark. meyve, sebze, deniz ürünleri, et ve süt ürünlerinin kalitesinin tespit edilmesi de dahil olmak üzere gıda güvenliği alanında ML tekniklerinin gelişimini gözden geçirmişlerdir [8]. Bu gıda ürünlerinin yanı sıra doğrudan şarap, peynir, yeşil çay, çilek, soya sütü, mantar, makarna, sosis ve likör gibi aromaların sınıflandırılması da rapor edilmiştir [9-16]. Fermantasyon sonucu oluşan uçucu organik bileşenler ve sıcaklık, mikroorganizma vb. nedenlerden dolayı oluşan yan ürünlerin analizinde de E-Nose, AOS ve elektronik dil sistemleri ML modelleri ile birlikte gıda kalite analizinde kullanılmasının yararlı bir araç olduğunu göstermiştir [4,17,18]

Bu çalışmada, çikolata, karanfil, tarçın, zencefil ve aroma olmayan ortam kokusu örneklenmiş ve saf örnekler üzerinden sistem oluşturulmuştur. Daha sonra E-Nose cihazının sensör dizisi ile farklı örneklerin tepkileri tespit edilmiş ve veri setleri elde edilmiştir. Daha sonra örüntü durumunu değerlendirmek için farklı ML modelleri oluşturulmuş ve karşılaştırılmıştır.

2. METOT

Aroma sınıflandırmak için geliştirilen E-Nose sistemi kuru hava, aromanın konulduğu bir bölme, sensör dizisi, elektronik valfler, veri toplama kartı (Data Acquisition System-DAQ) ile bilgisayardan oluşmaktadır. Kuru hava, belirli aralıklarla elde edilen aroma kokusunun bulunduğu bölmeyi temizlemek için kullanılır. Daha sonra E-Nose sistemi sahip olduğu sensör dizileri ile ilgili kokuya ait kimyasal bileşenleri sahip olduğu farklı sensörler yardımıyla DAQ ile ölçümünü yaptıktan sonra sinyal işleme/örüntü tanıma için bilgisayar ortamına aktarır. E-Nose sistemine ait en genel deneysel düzen Şekil-1'de gösterilmektedir.



Şekil 1. Aroma sınıflandırmak için geliştirilen E-Nose sistemine ait deneysel düzen.

2.1. Sensör Dizileri ve Veri Seti Oluşturma

E-Nose sisteminde, farklı hassasiyet karakteristiklerine sahip (metan, karbonmonoksit, karbondioksit, alkol, metan, bütan vb.) ve farklı tespit aralıklarında (30-10000 ppm*) gaz sensör dizilerinden toplamda 7 adet kimyasal sensör kullanılmıştır. Bu sensörler ile ilgili aromaya ait örüntülerin ölçümü yapılmış ve her aroma sınıfına ait veri seti elde edilmiştir. Bu araştırma çalışmasında, çikolata, karanfil, tarçın, zencefil ve aroma olmayan ortam kokusu örneklenmiştir ve saf örnekler üzerinden E-Nose sistemi gerçekleştirilmiştir.

2.2. Makine Öğrenmesi Modelleri

2.2.1. Lineer Diskriminant Analizi

Kernel Fisher Diskriminant analizinden türetilen Lineer Diskriminant Analizi (LDA), sınıflandırma ve verinin boyutunun azaltılması için kullanılan istatistiksel bir yöntemdir. Bu yöntem, sınıflar arası varyans oranını maksimuma çıkarmayı ve sınıf içi varyans oranını en aza indirmeyi amaçlamaktadır. Veri setinin mevcut hali bileşenleri ayırmak için çok elverişli olmadığı durumlarda veriyi daha kolay ayrılabilir hale getirmekte kullanışlı olan denetimli bir öğrenme algoritmasıdır [19]. İki veya daha fazla nesne veya olay sınıfını ayıran veya tanımlayan doğrusal bir özellik kombinasyonunu bulmak LDA'nın birincil hedefidir. Diskriminant fonksiyonu olarak da bilinen bu doğrusal kombinasyon, sınıflandırma için kullanılır. LDA'nın çalışabilmesi için öncelikle her sınıfa ait ortalama ve kovaryans matrisi belirlenir. Daha sonra sağlanan bilgileri kullanarak sınıflar arasındaki mesafeyi optimize eden bir projeksiyon vektörü hesaplanır. Veriler bu vektör kullanılarak yeni özellik uzayına dönüştürülür. Sınıflandırma görevlerinde LDA, sınıfları en iyi şekilde ayıran bir karar sınırı oluşturur. Bu karar sınırı, sınıflar arası dağılımı en üst düzeye çıkararak ve sınıf içi dağılımı en aza indiren bir hiperdüzlemdir. LDA biyoformatik, görüntü analizi ve örüntü tanıma gibi birçok alanda kullanılmaktadır. Gözlemleri özelliklerine göre birçok gruba ayırmanın gerekli olduğu senaryolarda uygulanır [19].

2.2.2. K-En Yakın Komşuluk Algoritması

Öklid tabanlı K-En Yakın Komşuluk (KNN), sınıflandırma ve regresyon görevleri için kullanılan basit ve sezgisel bir makine öğrenme algoritmasıdır. Eğitim aşamasında algoritma, tüm eğitim veri noktalarını özellik uzayında saklar. Sınıflandırma görevi için her veri noktası bir sınıf etiketiyle ilişkilendirilir. Tahmin aşamasında algoritma, yeni bir veri noktası için özellik uzayında bu noktanın k-en yakın komşularını belirler. Komşuları belirlemek için mesafe metriği olarak genellikle Öklid mesafesi kullanılır [19]. Ancak verilerin doğasına bağlı olarak Manhattan mesafesi, Minkowski mesafesi veya kosinüs benzerliği gibi diğer mesafe ölçümleri de kullanılabilir. Sınıflandırma için algoritma, yeni veri noktasına k-en yakın komşular arasında en yaygın sınıf etiketini atar. Algoritmanın hiper parametresi "k", bir veri kümesindeki sonuçları sınıflandırmak veya tahmin etmek için kullanılan en yakın komşuların sayısını ifade eder. "k", kullanıcı tanımlı bir parametredir ve "k"nin optimal değerini bulmak için önceden tanımlanmış matematiksel teknikler yoktur. Eğer "k" sayısı küçük seçilirse tahmin bölgesi sınırlanır ve sınıflandırıcının genel dağılımı daha az kesin hale gelir. Daha büyük "k" değerleri daha yumuşak bir karar sınırı sağlayabilir ancak yerel örüntüleri o kadar etkili bir şekilde yakalayamayabilir [19].

2.2.3. Karar Ağaçları

Sayısal ve kategorik verileri işleme yeteneğiyle ön plana çıkan Karar Ağacı (DTC), popüler bir denetimli makine öğrenimi algoritmasıdır. Böl ve yönet stratejisini uygulayan kural tabanlı bir algoritmadır ve hem regresyon hem de sınıflandırma için kullanılır. Sınıflandırma için girdi matrisindeki satır sayısı ile sınıf etiketlerinin sayısı eşit olmalıdır [19]. Ağaç, her bir düğümdeki verileri bölmek için en iyi özellik seçilerek özyinelemeli olarak oluşturulur. Bu süreç, önceden tanımlanmış bir ağaç derinliği, yaprak başına minimum örnek sayısı gibi bir durdurma kriteri karşılanana kadar devam eder. Karar ağacı, yukarıdan aşağıya doğru kök, karar düğümleri ve sonucu veren yapraklardan oluşur. Ağaçtaki en üst düğüm kök olarak adlandırılır ve veri kümesini belirli bir kritere göre en iyi şekilde bölen özelliği temsil eder. Bu kriter, her bir alt küme içindeki hedef değişkenin homojenliğini en üst düzeye çıkarmak için seçilir. İç düğümler, özelliklerin değerlerine dayalı karar noktalarını temsil eder. Her bir iç düğüm, ilgili özelliğin olası değerlerine karşılık gelen dallara sahiptir. Problem uzayının bölüneceği segment sayısı (ağaçtaki dal sayısı) çözüm için önemlidir ve asıl sorun ağaç oluşturulurken en iyi sınıflandırma için gerekli dal sayısının belirlenmesidir. Yapraklar, belirli bir örnek için tahmin sağlayan nihai çıktı düğümleridir. Sınıflandırma görevlerinde her bir yaprak bir sınıf etiketi ile ilişkilendirilir. Çok az veri ön işleme gerektirir ve özellikler arasındaki doğrusal olmayan ilişkiler doğal olarak yakalanır. Ancak karar ağaçları verilerdeki küçük değişikliklere karşı hassas olabilir ve dengesiz veri kümelerinde iyi performans göstermeyebilirler [19].

2.2.4. Çok Katmanlı Sinir Ağı

Çok katmanlı sinir ağı (MLP), sinyal işlemede yaygın olarak kullanılan ve bilginin tek yönde aktığı bir yapay sinir ağı türüdür. Derin öğrenmede temel bir mimaridir ve sınıflandırma, regresyon ve örüntü tanıma gibi çeşitli görevler için kullanılır. Bu algoritmayı kullanmanın arkasındaki motivasyon, bir sistemin veya veri örneklerinin doğrusal olmayan davranışını yakalamaya ve bunları tahmin etmeye dayanmaktadır. MLP, örüntüyü öğrenme ve genelleme

yeteneğine sahiptir [19]. MLP'de eğitim, istenen sonuçlara daha iyi yakınsama elde etmek için ağırlıkların güncellenmesi eylemi olarak tanımlanır ve denetimli bir öğrenme yaklaşımı kullanılır. Eğitim sırasında, modelin tahminleri gerçek hedef değerlerle karşılaştırılır ve fark bir kayıp fonksiyonu ile ölçülür. Geri yayılım daha sonra kaybı en aza indirmek için ağırlıkları ve bias değerlerini güncellemek için kullanılır. MLP'nin yapısı girdi katmanı, çıktı katmanı ve bu iki katman arasında yer alan bir veya daha fazla gizli katmandan oluşur. Ağdaki her düğüm, girdilerinin ağırlıklı bir toplamını gerçekleştiren ve sonucu bir aktivasyon fonksiyonundan geçiren bir nörondur. Yaygın aktivasyon fonksiyonları arasında sigmoid, hiperbolik tanjant (tanh) ve düzeltilmiş doğrusal birim (ReLU) bulunur. Aktivasyon fonksiyonları modele doğrusal olmayan bir özellik katar ve böylece verilerdeki karmaşık ilişkileri öğrenmesini sağlar. MLP performansı gizli katman sayısı, her katmandaki nöron sayısı, aktivasyon fonksiyonlarının seçimi ve öğrenme oranı gibi hiper parametrelerin seçimine bağlıdır. Optimum ağ yapısı, verilen görevi yerine getirebilecek ve genelleme yeteneğini en üst düzeye çıkarabilecek en düşük gizli katman sayısına sahip olmalıdır [19].

3. BULGULAR VE TARTIŞMA

E-Nose tabanlı aroma sınıflandırma için yapılan çalışmada 5 farklı sınıf için geleneksel makine öğrenmesi yöntemleri kullanılmış ve doğruluk (Accuracy/ACC), hassasiyet (Sensitivity/SENS), özgüllük (Specificity/SPEC), kesinlik (Precision/PREC) ve F-score değerleri elde edilmiştir. Tablo 1'de görüldüğü üzere, 5 farklı aroma sınıflandırma sonuçları içinde en başarılı makine öğrenmesi yöntemi bütün performans metrikleri için DTC olarak görülmektedir. Buna göre ilgili ML modeli, 93.16% ACC, 93.11% SENS, 98.31% SPEC, 93.35% PREC ve 93.12% F-score değerlerini elde etmiştir.



Chocolate (Çikolata), Clove (Karanfil), Cinnamon (Tarçın), Ginger (Zencefil), Unflavored (Aromasız Koku)

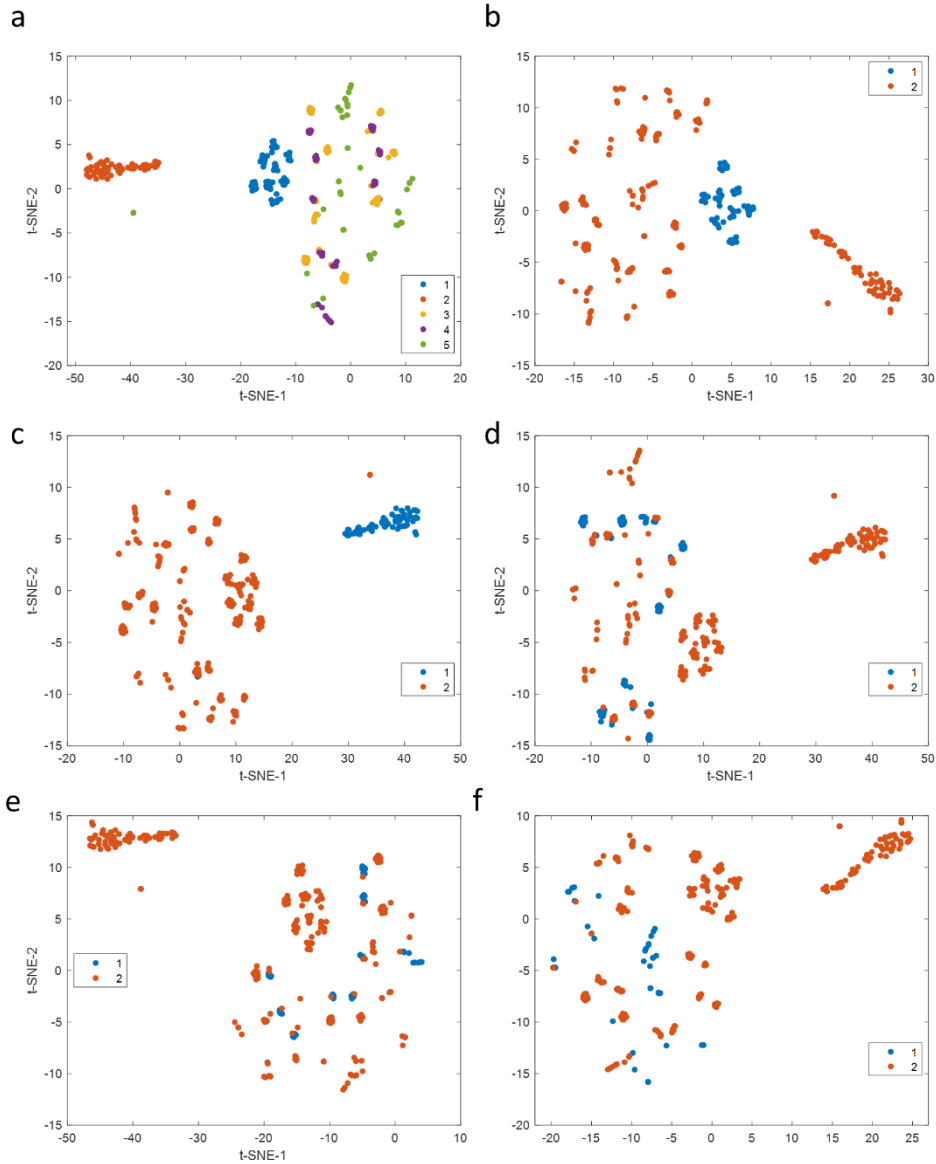
Şekil 2. Aroma sınıflandırma başarı grafiği. Ortama sınıflandırma sonuçları (üst sıra), 5-fold'a ait sınıflandırma sonuçları (orta sıra), karmaşık matrisi sonuçları (alt sıra sol DTC için, alt sıra sağ MLP için).

En başarılı ikinci ML modeli, MLP olarak gözlenmiştir. Bununla beraber, KNN ve LDA geleneksel ML modelleri diğer iki modeli göre aroma sınıflandırma daha düşük sınıflandırma sonucu elde etmiştir. Doğruluk oranı her iki model için 76.07% (KNN) ve 69.23% (LDA) olarak hesaplanmıştır. Hassasiyet, özgüllük, kesinlik ve F-score değerleri, KNN ve LDA için sırasıyla 76.29%-68.91%, 94.05%-92.33%, 76.39%-72.52% ve 74.94%-69.03% olarak elde edildiği gözlenmiştir. Aroma sınıflandırma başarısına ait ilgili grafikler Şekil 2’de gösterilmiştir.

Tablo 1. Aroma sınıflandırma sonuçları.

	ACC (%)	SENS (%)	SPEC (%)	PREC (%)	F-SCORE (%)
DTC	93.16	93.11	98.31	93.35	93.12
KNN	76.07	76.29	94.05	76.39	74.94
LDA	69.23	68.91	92.33	72.52	69.03
MLP	90.00	90.00	97.00	90.00	90.00

t-SNE (t-Distributed Stochastic Neighbor Embedding) grafiği birçok veride olduğu gibi aroma verileri arasında da sınıf içi ve sınıflar arası ayrıştırmayı ve kümelemeyi göstermektedir. Başka bir deyişle t-SNE, veri noktalarının benzerliklerini olasılıklara dönüştürür [2]. Buna göre birden fazla sınıfın kümeleneceği içinde (Şekil 3.a) karanfil ve çikolata aromasına ait kimyasal koku verilerinin diğer aroma verilerinden daha fazla ayrışabildiği gözlenmiştir. Bununla beraber, bir sınıfın diğer sınıflara göre ayrışması ve saçılması gözlemlendiğinde, çikolata ve karanfil aromalarının diğer kalan aromalardan daha fazla ayrışabildiği hesaplanmıştır.



Şekil 3. Aroma verileri için t-SNE saçılım grafikleri a. çikolata (1), karanfil (2), tarçın (3), zencefil (4), aroma yok (5). b. çikolata (1) ve diğer aromalar (2), c. karanfil (1) ve diğer aromalar (2), d. tarçın (1) ve diğer aromalar (2), e. zencefil (1) ve diğer aromalar (2), f. aroma yok (1) ve diğer aromalar (2) (İlgili sayılar grafikler üzerindeki aromalara ait etiketleri göstermektedir.)

Sınıf tabanlı aroma sınıflandırma sonuçlarına göre çikolata aromasına ait hassasiyet, özgüllük, kesinlik ve F-score sonucu 100% olarak hesaplanmıştır. Bununla beraber karanfil aroması için elde edilen hassasiyet, özgüllük, kesinlik ve F-score değerleri sırasıyla 91.30%, 97.87%, 91.30% ve 91.30% olarak bulunmuştur. Tarçın ve zencefil aromalarına ait sınıf tabanlı tahmin sonuçları ise hassasiyet ve özgüllük değerleri için $\geq 87.00\%$ olarak gözlenmiştir. Kesinlik ve F-score değerleri de yine $\geq 80.00\%$ olarak elde edilmiştir.

Tablo 2. DTC için sınıf tabanlı aroma tahmin sonuçları.

	SENS (%)	SPEC (%)	PREC (%)	F-SCORE (%)
Çikolata	100	100	100	100
Karanfil	91.30	97.87	91.30	91.30
Tarçın	90.91	94.74	80.00	85.11
Zencefil	87.50	98.92	95.45	91.30
Aromasız Koku	95.83	100	100	97.87
Ortalama Değer	93.10	98.30	93.35	93.11

4. SONUÇ

Elektronik burun (E-Nose), aromalara ait kokuları ayırt etmek için hızlı ölçümler yapabilen, uygun maliyetli ve güçlü bir elektronik cihazdır. Çevre, tıp ve gıda bilimleri gibi birçok disiplinde, temel olarak ürünlerin kalitesini değerlendirmek ve gıda bozulmasına atfedilebilecek kötü koku/tatları tespit etmek amacıyla yaygın olarak kullanılmaktadır. Gıda işleme sırasında açığa çıkan aromalardan sorumlu moleküller insan burnu tarafından tanınabildiğinden, işlenmiş gıda ürünlerinde meydana gelen değişiklikleri tespit etmek için E-Nose kullanmak mümkün olabilir. Ayrıca aromatik bileşiklerin oluşumu ile işleme sırasında kimyasal kirleticilerin oluşumu arasındaki ilişki nedeniyle E-Nose, toksik bileşiklerin oluşumunu tahmin etmek için bir araç olarak da kullanılabilir. Bu çalışmada 4 farklı gıdaya ait aroma ile aromasız kokunun analizini elde etmek ve sınıflandırmak için E-Nose sistemi kurulmuş ve kullanılmıştır. Buna göre DTC ve MLP ile özellikle çikolata ve karanfil aromalarına ait kokularda yüksek sınıflandırma doğruluğu ($\geq 90.00\%$), hassasiyet ($\geq 90.00\%$) ve özgüllük değerleri elde edilmiştir. Böylece bu sistemin, bu gıdalardaki ayırışım ve tahmin seviyelerini doğrudan ölçmedeki etkinliği ortaya koyulmuştur. Bu sonuçlara dayanarak, E-Nose ve makine öğrenmesi modellerinin diğer gıda matrislerindeki etkinliğinin doğrulanması gelecek çalışmalar için faydalı olacaktır.

Yazar Katkıları

Yazarlar makaleye eşit derecede katkı sağlamıştır.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Destek ve Teşekkür Beyanı

Bu çalışma, Bandırma Onyedi Eylül Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından BAP-21-1004-001 numaralı proje kapsamında desteklenmiştir.

KAYNAKÇA

- [1] D. Ma, C. Liu, F. Wu, Z. Li, X. Wu, J. Gao, H. Zhao, Z. Zhang, "The Quality Detection and Recognition for Food Seasoning Based on an Artificial Olfactory System", IEEE Instrum. Meas. Mag., vol:25 no:9, pp. 42-52, 2022.
- [2] Y. Durmuş, A.F. Atasoy, "Application of multivariate machine learning methods to investigate organic compound content of different pepper spices", Food Biosci., vol:51, pp. 102216, 2023.
- [3] P.-A. Chen, C.-I. Liu, K.-R. Chen, "Determining the Relationship between Aroma and Quality of Bao-Chung Tea by Solid-Phase Microextraction (SPME) and Electronic Nose Analyses", Horticulturae, vol:9, pp. 930, 2023.
- [4] M. Mesías, J.D. Barea-Ramos, J. Lozano, F.J. Morales, D. Martín-Vertedor, "Application of an Electronic Nose Technology for the Prediction of Chemical Process Contaminants in Roasted Almonds", Chemosensors, vol:11, 2023.
- [5] A. Ren, A. Zahid, A. Zoha, S.A. Shah, M.A. Imran, A. Alomainy, Q.H. Abbasi, "Machine Learning Driven Approach Towards the Quality Assessment of Fresh Fruits Using Non-Invasive Sensing", IEEE Sens. J., vol:20, pp. 2075–2083, 2020.
- [6] M. Pardo, G. Sberveglieri, "Coffee analysis with an electronic nose", IEEE Trans. Instrum. Meas., vol:51, pp. 1334–1339, 2002.
- [7] P.K. Kundu, A. Chatterjee, P.C. Panchariya, "Electronic Tongue System for Water Sample Authentication: A Slantlet-Transform-Based Approach", IEEE Trans. Instrum. Meas., vol:60, pp. 1959–1966, 2011.
- [8] M. Anly Antony, R.S. Kumar, "A Comparative Study on Predicting Food Quality using Machine Learning

- Techniques”, in: 2021 7th Int. Conf. Adv. Comput. Commun. Syst., IEEE, pp. 1771–1776, 2021.
- [9] J.X. Leon-Medina, M. Anaya, D.A. Tibaduiza, “New Electronic Tongue Sensor Array System for Accurate Liquor Beverage Classification”, *Sensors*, vol:23, pp. 6178, 2023.
- [10] H. Wang, Y. Sui, J. Liu, B. Kong, H. Li, L. Qin, Q. Chen, Analysis and comparison of the quality and flavour of traditional and conventional dry sausages collected from northeast China”, *Food Chem. X.*, vol:20, pp. 100979, 2023.
- [11] Y. Luo, R. Wang, H. Han, S. Wang, J. Ma, C. Yuan, Y. Ren, “Effects of dry-salting and brine-pickling on physicochemical properties and flavor of spaghetti squash shreds”, *Food Biosci.*, vol: 56, pp. 103268, 2023.
- [12] T. Feng, W. Cai, D. Chen, S. Song, L. Yao, M. Sun, H. Wang, C. Yu, Q. Liu, Y. Dang, “Analysis of umami taste and their contributing compounds in edible fungi based on electronic tongue, sensory evaluation, and chemical analysis”, *J. Food Sci.*, 2023.
- [13] H. Ji, D. Pu, W. Yan, Q. Zhang, M. Zuo, Y. Zhang, “Recent advances and application of machine learning in food flavor prediction and regulation”, *Trends Food Sci. Technol.*, vol:138, pp. 738–751, 2023.
- [14] M. Masuda, Y. Terada, R. Tsuji, S. Nakano, K. Ito, “Time-Series Sensory Analysis Provided Important TI Parameters for Masking the Beany Flavor of Soymilk”, *Foods*, vol: 12, pp. 2752, 2023.
- [15] L. Wu, X. Wang, J. Hao, N. Zhu, M. Wang, “Geographical Indication Characteristics of Aroma and Phenolic Acids of the Changping Strawberry”, *Foods*, vol:12, pp. 3889, 2023.
- [16] X. Zeng, R. Cao, Y. Xi, X. Li, M. Yu, J. Zhao, J. Cheng, J. Li, “Food flavor analysis 4.0: A cross-domain application of machine learning”, *Trends Food Sci. Technol.* Vol: 138, pp: 116–125, 2023
- [17] S. Wang, Q. Zhang, C. Liu, Z. Wang, J. Gao, X. Yang, Y. Lan, “Synergetic application of an E-tongue, E-nose and E-eye combined with CNN models and an attention mechanism to detect the origin of black pepper”, *Sensors Actuators A Phys.*, vol:357, pp. 114417, 2023.
- [18] N. Yuan, X. Chi, Q. Ye, H. Liu, N. Zheng, “Analysis of Volatile Organic Compounds in Milk during Heat Treatment Based on E-Nose”, *E-Tongue and HS-SPME-GC-MS*, *Foods*, vol:12, pp. 1071, 2023.
- [19] E. Alpaydm, “Introduction to Machine Learning”, MIT Presss, Second Edi, 2010.