

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**MANTAR BULAŞMIŞ ELMALARIN ELEKTRONİK BURUN
KULLANILARAK TESPİTİ**

YÜKSEK LİSANS TEZİ

Esra KOCAMANOĞLU

OCAK 2024
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**MANTAR BULAŞMIŞ ELMALARIN ELEKTRONİK BURUN
KULLANILARAK TESPİTİ**

Esra KOCAMANOĞLU

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
" ELEKTRONİK YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 02 / 01 / 2024

Tezin Savunma Tarihi : 19 / 01 / 2024

Tez Danışmanı : Doç. Dr. Önder AYDEMİR

Trabzon 2024

ÖNSÖZ

“Mantar Bulaşmış Elmaların Elektronik Burun Kullanılarak Tespiti” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik ve Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilim insanı olma yolundaki ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Doç. Dr. Önder AYDEMİR’e teşekkürü bir borç bilirim.

Tez çalışması sürecinde bana desteklerini esirgemeyen Elektrik ve Elektronik Mühendisliği Bölümü’ndeki tüm değerli hocalarıma ve asistan arkadaşlarıma teşekkürlerimi sunarım.

Son olarak, öğrenim hayatım boyunca desteğini esirgemeyen ve üzerimde büyük emekleri olan annem Emine KOCAMANOĞLU ve babam Turan KOCAMANOĞLU’na, abim Dr. Yavuz O. KOCAMANOĞLU, ablam Elif KOCAMANOĞLU’na teşekkür eder, minnettarlığımı sunarım.

Bu araştırmanın, bilim dünyasına, ilgilenenlere ve ülkemize faydalı olmasını dilerim.

Esra KOCAMANOĞLU

Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Mantar Bulaşmış Elmaların Elektronik Burun Kullanılarak Tespiti” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. ÖNDER AYDEMİR’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 19/01/2024

Esra KOCAMANOĞLU

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
ŞEKİLLER DİZİNİ.....	IX
SEMBOLLER VE KISALTMALAR DİZİNİ	XII
1. GENEL BİLGİLER	1
1.1. Elma Meyvesinin Özellikleri.....	4
1.2. <i>Penicillium expansum</i> Mantar Özellikleri.....	5
1.3. <i>Penicillium crustosum</i> Mantar Özellikleri	6
1.4. <i>Aspergillus niger</i> Mantar Özellikleri.....	8
1.5. Biyolojik Burun.....	9
1.6. Burnun Yapısı.....	10
1.7. Koku Alma Prosedürü	11
1.8. Elektronik Burun Yapısı.....	13
1.8.1. PEN3 Elektronik Burun	15
1.9. Elektronik Burun Uygulama Alanları	17
1.10. Elektronik Burun Uygulamalarında Kullanılan Sensörler	23
1.10.1. Metal Oksit Sensörler.....	26
1.10.2. Metaloksit Yarı iletken Alan-Etkili Transistörler [MOSFET] Sensörler.....	28
1.10.3. Optik Sensörler	29
1.10.4. Piezoelektrik Sensörler	30
1.11. Örüntü Tanıma Birimi	31
1.12. E-Burun Yazılım	31
1.12.1. İşaret İşleme Aşamaları.....	31
1.12.2. İşaret Koşullama Ön işlemler.....	31
1.13. Öznitelik Çıkartma	32
1.14. Sınıflandırma	32
2. YAPILAN ÇALIŞMALAR.....	33
2.1. Veri Seti Tanıtımı.....	33
2.2. Sensör Tepkileri	35

2.3. Öznitelikler.....	38
2.3.1. Ortalama.....	38
2.3.2. Medyan.....	38
2.3.3. Varyans	38
2.3.4. Standart Sapma	39
2.3.5. İntegral	39
2.3.6. Diferansiyel	40
2.3.7. Gradient.....	40
2.3.8. Bant Genişliği Özniteliği	42
2.3.9. Dalgacık Dönüşümü.....	42
2.3.10. Komşuluk Bileşen Analizi	46
2.3.11. Lineer Diskriminant Analizi	46
2.4. Sınıflama Algoritmaları.....	48
2.4.1. k-En Yakın Komşuluk Algoritması	48
2.4.2. Destek Vektör Makineleri	50
2.4.3. Karar Ağacı	52
2.4.4. Naive Bayes Yöntemi	54
3. BULGULAR.....	57
3.1. Sensör Eliminasyonu.....	57
3.2. Öznitelik Çıkarma	57
3.3. Bant Genişliği Özniteliği ile Elde Edilen Sonuçlar.....	58
3.4. Dalgacık Dönüşümü Özniteliği ile Elde Edilen Sonuçlar	59
3.5. İstatiksel Öznitelikler Birlikte Kullanılması İle Elde Edilen Sonuçlar	59
3.6. İstatiksel Özniteliklerin Dalgacık Dönüşümü ile Birlikte Kullanımı	60
3.7. Doğrusal Diskriminant Analizi İşlemi	61
3.8. Sınıflama İşlemi	62
3.8.1. k-En Yakın Komşuluk Sınıflama Sonuçları.....	62
3.8.2. Destek Vektör Makineleri Sınıflama	64
3.8.3. Karar Ağacı	66
3.8.4. Naive Bayes Sınıflama.....	67
4. TARTIŞMA	70
5. SONUÇLAR VE ÖNERİLER.....	72
6. KAYNAKLAR	73
ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

MANTAR BULAŞMIŞ ELMALARIN ELEKTRONİK BURUN KULLANILARAK TESPİTİ

Esra KOCAMANOĞLU

Karadeniz Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. ÖNDER AYDEMİR

2024, 80 Sayfa

Elektronik burunlar makine öğrenmesi algoritmaları ile insan koku alma sistemini taklit ederek koku tanımlaması ve sınıflandırılmasını sağlayan mekanizmalardır. İçerdiği sensörler sayesinde insan burnunun ayırt edemediği gazların tanımlanmasına örneğin meyvedeki çürümelerin erkenden teşhis edilmesine olanak sağlar. Elma depolamada mantar kaynaklı bozulma ve çürümelere karşı hassas olduğu için elektronik burun bu tür problemlere erken teşhis avantajı sağlar. Bu çalışmada kullanılan veri seti taze elmalar ve *Aspergillus niger*, *Penicillium expansum* ve *Penicillium crutosum* mantarı enjekte edilmiş elmalardan eşit sayıda toplam 160 adet örnek alınarak oluşturulmuştur. Elma karakteristiklerini belirlemek için belirli veriler elenerek sırasıyla öznitelik çıkarma, doğrusal diskriminant yöntemi uygulanmıştır. K en yakın komşuluk, karar ağacı, destek vektör makineleri ve naive bayes sınıflama yöntemleri ile eğitim ve test doğrulukları belirlenmiştir. Taze elmalar ve *Aspergillus niger*, *Penicillium expansum*, *Penicillium crutosum* mantarı enjekte edilmiş elmaların 4 lü sınıflamasında, K-en yakın komşu sınıflandırma yöntemi sayesinde en yüksek test doğruluğu %99.33'e ulaştığı gözlenmiştir. Çalışma sonuçları, elektronik burun sayesinde elmalardaki bozulmanın erkenden tespitinin yapılabileceğini göstermiştir.

Anahtar Kelimeler: Elektronik Burun, Elma, Mantar, Sınıflandırma

Master Thesis

SUMMARY

DETERMINATION OF FUNGUS INFECTED APPLES BY USING ELECTRONIC NOSE

Esra KOCAMANOĞLU

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electric-Electronic Graduate Program
Supervisor: Assoc. Prof. ÖNDER AYDEMİR
2024, 80 Pages

Electronic noses mimic the human olfactory system using machine learning algorithms to enable odor identification and classification. Equipped with sensors, they can identify gases imperceptible to the human nose, allowing for early detection of issues such as fruit decay. Given the apple's susceptibility to fungal deterioration during storage, the electronic nose provides an advantage in early diagnosis of these problems. In this study, a dataset was created with a total of 160 samples, including an equal number of fresh apples and apples injected with *Aspergillus niger*, *Penicillium expansum*, and *Penicillium crutosum* fungi. To determine apple characteristics, specific data were eliminated, and sequential processes of feature extraction and linear discriminant analysis were applied. Training and test accuracies were determined using K-nearest neighbors, decision trees, support vector machines, and naive Bayes classification methods. In the 4-class classification of fresh apples and apples injected with *Aspergillus niger*, *Penicillium expansum*, and *Penicillium crutosum* fungi, the K-nearest neighbors classification method achieved the highest test accuracy of 99.33%. The study results demonstrate that the electronic nose enables early detection of decay in apples.

Key Words: Electronic Nose, Apple, Mushroom, Classification

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. <i>Penicillium expansum</i> ile enfekte edilmiş elma meyvesindeki mavi küf çürüğü	6
Şekil 2. Burun Boşluğunun Genel Yapısı.....	10
Şekil 3. Koku alma sistemi genel yapısı.....	12
Şekil 4. Koku alma sistem mekanizması	13
Şekil 5. Elektronik burun ve biyolojik burun koku alma sistemleri karşılaştırılması	14
Şekil 6. PEN3 Elektronik Burun	16
Şekil 7. Gaz sensörleri çalışma prensibi (Kızıl, 2011)	24
Şekil 8. Bazı sensör türlerinin performans göstergeleri	26
Şekil 9. Gaz sensör uygulamalarında kullanılan metal oksit yüzdeleri	27
Şekil 10. Mosfet çeşitleri.....	29
Şekil 11. İşaret İşleme ve Sınıflandırma Aşamaları	31
Şekil 12. Çalışmada kullanılan elektronik burun ve şeması.....	34
Şekil 13. <i>Aspergillus niger</i> 4. ve <i>Aspergillus niger</i> 20.örneğe ait sensör tepkileri	36
Şekil 14. Taze elma 4. ve Taze elma 20. örneğe ait sensör tepkileri.....	36
Şekil 15. <i>Penicillium Crustosum</i> 4. ve <i>Penicillium Crustosum</i> 20. örneğe ait sensör tepkileri	37
Şekil 16. <i>Penicillium Expansum</i> 4. ve <i>Penicillium Expansum</i> 20. örneğe ait sensör tepkileri.....	37
Şekil 17. Gradyan grafiği.....	41
Şekil 18. Daubechies-3 ana dalgacık ve ölçekleme fonksiyonu.....	45
Şekil 19. Lineer Diskriminant Analizi.....	47
Şekil 20. K-En Yakın Komşuluk Algoritması.....	50
Şekil 21. Örnek Destek Vektör Makinesi Uygulaması.....	52
Şekil 22. Karar Ağacı Öğrenme Algoritması Örneği	53
Şekil 23. Naive Bayes Yöntemi.....	56
Şekil 24. DDA işlemi öncesi	61
Şekil 25. DDA işlemi ile boyutu azaltılmış verilerin 3 boyutlu görüntüsü	62
Şekil 26. K-En Yakın Komşuluk Test Doğruluğu.....	63
Şekil 27. K-En Yakın Komşuluk Eğitim Doğruluğu.....	64
Şekil 28. Destek Vektör Makinesi Test Doğruluğu.....	65

Şekil 29. Destek Vektör Makinesi Eğitim Doğruluğu.....	65
Şekil 30. Karar Ağacı Test Doğruluğu	66
Şekil 31. Karar Ağacı Eğitim Doğruluğu	66
Şekil 32. Naive Bayes Test Doğruluğu	67
Şekil 33. Naive Bayes Eğitim Doğruluğu	68



TABLÖLAR DİZİNİ

Sayfa No

Tablo 1. Elektronik burun ile insan burnu parametreleri karşılaştırılması	15
Tablo 2. PEN3 Elektronik Burunda Kullanılan Sensörler, Zhao,2022	16
Tablo 3. Elektronik burunda en çok kullanılan sensörler, avantajları ve dezantajlar.....	25
Tablo 4. Veri Seti Değerleri	34
Tablo 5. Çalışmada Kullanılan Elektronik Burundaki Sensörler	35
Tablo 6. Komşuluk Bileşen Analizi	58
Tablo 7. Bant Genişliği Sonuçları	58
Tablo 8. Dalgacık dönüşümü özneliği sonuçları	59
Tablo 9. İstatistiksel özneliliklerin birlikte kullanım doğruluk sonuçları	60
Tablo 10. Test ve Eğitim Doğruluklarında Ortalama En Yüksek Sonuçlar	68
Tablo 11. k-En Yakın Komşuluk Sınıflama farklı oran sonuçları.....	69

SEMBOLLER VE KISALTMALAR DİZİNİ

PC: *Penicillium crustosum*

PE: *Penicillium expansum*

AN: *Aspergillus niger*

k-EYK: k En Yakın Komşuluk

DVM: Destek Vektör Makinesi

DDA: Doğrusal Diskriminant Analizi

KA: Karar Ağacı

NB: Naive Bayes

TBA: Temel Bileşen Analizi

μ : Ortalama

N: Örnek Sayısı

Std: Standart Sapma

Var: Varyans

Sk: Örnek Sinyal

FD: Fourier Dönüşümü

KZFD: Kısa Zamanlı Fourier Dönüşümü

Ψ : Dalgacık Fonksiyonu

1. GENEL BİLGİLER

Meyve ve sebzeler, modern tarım ekonomisinde hayati bir konuma sahiptir ve dünyanın önde gelen tarım ürünlerindendir. İnsan sağlığı ve beslenmesinde sindirim sisteminin işlevini desteklemek için vitaminler ve mineral maddelerce zengin olması bakımından önemli bir yer tutmaktadır. Meyve kalitesinin gelişimi, toplum sağlığına ve tarımsal gelişime katkı sağlayabilir. Elmalar; her mevsim erişilebilir olması, ekonomik, lezzetli ve dayanıklı olması sebebiyle tüketimi oldukça yaygın olan bir meyve çeşididir. Ayrıca birçok vitamin ve mineral içermesinin yanı sıra zengin su içeriğine sahiptir. Elmanın sahip olduğu lifli yapısı, glisemik endeksinin düşük olması içeriğinde yer alan antioksidanların, fitokimyasalların ve posanın sağlık üzerine olumlu etkileri yapılan çalışmalarda sıklıkla üzerinde durulmuş ve bilimsel olarak ispatlanmıştır. Elmanın yeterli miktarda tüketimi ile astım, diyabet, kardiyovasküler hastalıklar gibi kronik hastalıklar ve çeşitli kanser türleri gibi birçok hastalığın görülme riskini düşürdüğü gözlemlenmiştir (Küçükkömürler & Karakuş 2009).

Elma dünya çapında 2021/22 sezonunda bir önceki sezona göre yaklaşık %1,6 oranında artarak 81,8 milyon ton üretim olacağı öngörülen, Türkiye’de ise TÜİK 2022 yılı bitkisel üretim 1. tahminine göre elma üretimi bir önceki yıla göre %4,5 oranında artarak 4,7 milyon ton olacağı tahmin edilen üretim ve tüketimi yüksek bir gıda ürünüdür (TÜP, 2022). Fakat hasat sonrası uygun olmayan depolama nedeniyle mantarların neden olduğu enfeksiyonlara karşı hassastır (Özgönen & Kılıç 2009). Hastalıklar her yıl elma endüstrisinde ciddi ekonomik kayıplara neden olabilmektedir. Farklı hastalıkların ürettiği semptomlar benzer olabileceğinden ve bazen aynı anda ortaya çıkabileceğinden ayrıca yüzeyden bulunması zor olabilen birkaç küflü elmanın zamanında tanımlanması çiftçiler için zor olması sebebiyle hasat sonrası ciddi kayıplara neden olabilir.

Hastalıklar meyve üretimini azaltmanın yanı sıra meyve kalitesini de olumsuz etkiler. Mahsulün kalite ve miktarını iyileştirmek için hastalıklardan korumak önemlidir. Meyveleri hastalıklardan korumak için zamanında bir tespit sistemi ve doğru şekilde teşhis edilebilmesi etkin hastalık yönetimi için çok önemli bir adımdır. Meyvedeki hastalık hakkında erken ve doğru teşhis çiftçinin uygun tedbirleri almasına ve doğru tedavi yöntemleri uygulamasına yardımcı olur. Bu durum da ekonomik ve çevresel faydalar elde edilmesini sağlar. Fakat erken ve doğru teşhisin uygulanabilmesi için çiftçilerin ürünlerini sürekli izlemesi ve uzmanlarla etkileşimde kalabilmesi gerekir. Uzmanların da hastalıklar, semptomlar ve

tedavi süreleri hakkında yetkin ve kapsamlı bilgiye sahip olması önemlidir. Ayrıca uzmanlar tarafından uygulanabilen ve sadece birkaç numüne incelenmesine imkan veren bazı meyve hastalıkları mevcuttur. Bu sebeplerden ötürü hastalıkları erken aşamada tespit edebilen ve uygun tedavileri ve önerileri zamanında sağlayabilen otomatik bir sisteme ihtiyaç duyulmaktadır (Khan, 2021).

Gaz kromatografisi-kütle spektrometrisi (Pan vd., 2014), çeşitli kromatografi yöntemleri TLC (İnce Tabaka Kromatografisi), GC (Gaz Kromatografisi), HPLC (Yüksek Performanslı Sıvı Kromatografisi) (Shephard & Leggott, 2000) meyve, sebzedeki hastalık ve gaz tespiti için uzun yıllardır kullanılmaktaydı. Fakat bu yöntemlerdeki cihazlar pahalı ve zaman alıcıdır. Son yıllarda ise bu alanda yakın kızılötesi spektroskopi (Guo vd., 2016) ve yapay görme (Bhargava & Bansal, 2020) kullanıldığı halde bu yöntemler bakterileri karakterize edebilme konusunda yetersiz kalmıştır.

Ürün kalitesini belirleyen unsurlardan biri olan koku, tüketiciler için temel gereksinim olan tarımsal ürün kalitesini belirlemede önemli bir ölçüttür. Modern tarımda mahsul, toprak, hava ve çevre koşulları hakkında doğru bilgi elde etmek, kalite kontrol ve endüstriyel süreçlerin izlenmesi için çeşitli sensör teknolojileri kullanılmaktadır (Wilson, 2013). Elektronik burunlar yapısındaki sensör teknolojisi sayesinde tarım ürünlerinin tazelik değerlendirmesi, kalitelerinin belirlenmesi, türlerinin sınıflandırılması, coğrafi köken tanımlaması ve hastalık tespitinde yaygın olarak kullanılır. Analiz yöntemlerinin basit, hızlı, tahribatsız, ucuz ve spesifik olması, tekrarlanabilirliğinin olması tercih edilme sebeplerindendir (Jia vd., 2019).

Elektronik burun insandaki koku alma sisteminin taklit edilmesiyle oluşturulmuştur. İnsan koku alma sisteminin performansı oldukça dikkat çekici olup, bu sistemin fonksiyonelliği ve detayları bilim insanlarını koku alma mekanizması geliştirmeye teşvik etmiştir. İnsan burnu, parfümler (kozmetik, sabunlar vb.), gıda maddeleri (balık, et, peynir vb.) ve içecekler tanımlama ve değerlendirilmesinde kullanılan önemli bir sistemdir (Gardner & Bartlett 1994). Memelilerin koku alma mekanizması çok sayıda farklı koku molekülünü tanıyıp, ayırt etmeye olanak sağlar. İnsan burnunda kokunun algılanması reseptörlerin koku molekülleri tarafından uyarılması ile başlar. Beyin, farklı koku verici uyarılar arasında ayırım yapılmasına izin verir. Koku alma algısının çeşitliliği sağlamak için hangi reseptörlerin veya hangi nöronların aktive edildiğini ayırt eder (Buck & Axel, 1991). Fakat insan burnunda oluşan yorgunluk durumu sonucunda karbon monoksit ve karbondioksit gibi gazları belirli süre sonrasında algılamamaya ve duyarlılığın azalmasına

sebeptir. Kokulara verilen duygusal tepkiler sonucu kişiye bağımlılık özelliği göstermektedir. Elektronik burunun duygusal tepki vermemesi ve hassasiyetinin insan burnuna göre yüksek olması yıllarca aynı işi görebilmesine, kullanılan sensör dizisi sayesinde insan burnunun algılayamadığı gazları rahatlıkla algılayabilmesine, örneğin bozulan besinlerin erken tespit edilebilmesine olanak sağlamaktadır (Öztürk, 2005).

Elektronik Burun, yapısında bulunan kimyasal sensör dizisi sayesinde, dış dünyadaki kokuları algılayıp, insan burnunun algılayamadığı seviyelerdeki kokular üzerinde hassas ölçüm yapabilir. Aynı zamanda buhar ve gaz analizlerinde de kullanılabilen düşük maliyetli cihazlardır (Saraoğlu, 2008). Elektronik burun temel olarak algılama ve örüntü tanıma sisteminden meydana gelir. Algılama sisteminde insan burnundaki reseptör hücrelerinin yerini alan, farklı kokulara farklı tepkiler veren kimyasal sensör dizisi yer almaktadır. Kokunun sınıflandırması işleminde karar veren yapay zekâ modeli, daha önceden toplanan sensör verilerini makine öğrenmesindeki yöntemler ile eğiterek örüntü tanıma sürecini gerçekleştirir (Özalp & Uçar, 2016; Beyhan & Çetin, 2019).

Elektronik burun sistemleri geçmişten günümüze kadar tıp, ilaç sektöründen, gıda analizi, kalite kontrolüne, savunma, güvenlik sektöründen, tarım, hayvancılığa; makine, otomasyon sektöründen, parfümeri, kozmetiğe kadar birçok alanda kullanılmıştır (Efe, 2006). Makine öğrenmesi ve yapay zekâ teknolojisinin desteği ile farklı alanlarda geliştirilmesi devam etmektedir.

Elektronik burun teknolojisi modern tarımda önemli yere sahip olan meyve ve sebzelerin kalite tespitine büyük katkı sağlamaktadır. Yapılan çalışmalarda meyve ve sebzelerde oluşan mantarların sınıflaması ve tespitinde elektronik burun tercih edildiği görülmektedir. Modern tarımda önemli bir yere sahip olan elmalarda hasat sonrası uygun olmayan depolama koşulları nedeniyle oluşan mantarların tespitinde elektronik burun geleneksel yöntemlere göre hızlı, basit, tahribatsız ve tekrarlanabilir olmasının hasat sonrası depolamadaki kayıpları en aza indirgeyebildiği gözlemlenmiştir. Bazı çalışmalar gaz sensörlerinin meyve hasarını ve bozulmasını izlemede büyük potansiyele sahip olduğunu göstermiştir. Fakat az sayıda çalışma elmalarda küf tespitine, özellikle farklı küflerin ayırımına çok az dikkat etmiştir.

Bu çalışmada önceki araştırmalardan esinlenerek, taze ve küflü elmaları (*Aspergillus niger*, *Penicillium expansum* ve *Penicillium crustosum* ile yapay aşılama) tespit etmek ve tanımak için elektronik burun kullanılmıştır.

1.1. Elma Meyvesinin Özellikleri

Binlerce yıllık zengin tarihe sahip olan ve sofralarımızın vazgeçilmez ürünlerinden biri olan elma; evrensel olarak tüketimi çok fazla olmasının yanında çok çeşitli şartlarda üretimi yapılabilen bir meyve türüdür. Asya ve Avrupa kıtalarında tarihten önceki zamanlarda dahi yetiştiriciliği yapılan elma Rosales takımının, Rosaceae familyasının, Pomoideae alt familyasından Malus cinsine aittir (İmrak vd., 2010). Kültüre ne zaman alındığı bilinmemekle birlikte M.Ö. 4000 ila M.Ö. 2000 yılları arasında keşfedilen elmanın anavatanı 1 Anadolu'nun dahil olduğu Güney Kafkaslardır.

Orta Çağda elma Anadolu'dan Yunanistan ve İtalya yolu ile bütün Avrupa'ya yayılmıştır. 17. yüzyılda Amerika'ya giden Avrupalı kaşifler ve ilk göçmenler ile Kuzey Amerika'ya götürülmüş ve sonrasında tüketimi yaygınlaşmıştır.

Elma dünyada 6500, Türkiye'de ise 460 çeşide sahip olması açısından çeşitlilik bakımından zengin bir meyve türüdür. Dünyada 2023 verilerine göre elma üretiminin en fazla olduğu üç ülke sıralaması Çin, Amerika Birleşik Devletleri, Polonya olmakla birlikte ülkemiz 2 milyon ton üretimi ile 4.sırada yer almaktadır. Coğrafi koşullarının uygunluğu nedeni ile ülkemizin hemen her yerinde yetişmeye uygun bir meyve çeşididir. Ülkemizde en uygun yetiştirme alanını Kuzey Anadolu, Karadeniz kıyı bölgesi ile İç Anadolu ve Doğu Anadolu yayları arasındaki geçit bölgeleri ve son zamanlarda güneyde göller bölgesinde bulmuştur (Cennet, 2009).

Elma tarih boyunca birçok kültürde ve mitolojide önemli bir rol oynamıştır. Antik dönemde Mezopotamya, Anadolu, Mısır, İtalya, Hellas, İspanya gibi çeşitli kültürlerde gerek gündelik yaşamdaki aktif kullanımı gerekse gençlik, sağlık, bolluk ve bereketin sembolü gibi değerleri simgelemesi açısından geçmişten günümüze değerini korumuştur .

Elmalar geçmişten günümüze kadar birçok medeniyette tıpta kullanımı yaygın olan bir meyve türüdür. Yüksek lifli yapısı sayesinde sindirim sağlığı açısından oldukça destekleyicidir. Elma ve elma suyunun glisemik indeks ve glisemik yük değeri düşük besinler içinde yer alması kan şekerinin sabit tutulmasında yardımcı olur. İçerdiği potasyum, A, C ve E vitaminleri sayesinde yüksek besin değerine sahip olan elma bağışıklık sistemini önemli ölçüde destekler. Elma tüketimi; kötü kolesterol (LDL) düşürdüğü, iyi kolesterol (HDL) kolesterolü arttırdığı bu sayede kardiyovasküler sağlığı desteklediği bilinmektedir. İçerdiği potasyumun kalp sağlığını korumada destekleyici olması ve lifli yapısının kilo kontrolünde yardımcı olması kullanım amacını artırır. Vitaminlerin yanı sıra fitokimyasal

grubu içerisinde yer alan flavonoidler de antioksidant özellik taşımaktadır. Bu özellikleri sayesinde bazı kanser türleri, akciğer rahatsızlıkları, diyabet ve kardiyovasküler hastalıklar gibi hastalıkların görülme riskini düşürmektedir. Ayrıca yapılan çalışmalarda tüketiminin astım ve Alzheimer riskini düşürdüğü kanıtlanmıştır. Elmadaki A ve C vitaminleri ile potasyum, kalsiyum, magnezyum ve sodyum gibi elementlerin birleşerek birtakım tuzları oluşturması kandaki asit baz dengesi üzerinde olumlu etkiler oluşturur. Ayrıca depolarda uzun süre saklanabilme koşullarına sahip olan elmaların suyu, çayı, sirkesi, şarabı, pekmezi, kompostası, hoşafı yapılabilmesi açısından çok çeşitli kullanım alanlarına sahiptir (Küçükkömürler & Karakuş, 2009).


1.2. *Penicillium expansum* Mantar Özellikleri

Penicillium expansum toprakta ve tüm dünyada yaygın, mavi küf hastalığına sebep olan *penicillium* türüne ait bir mantar çeşididir. Enfekte etmek için elma, Avrupa armudu, Asya armudu, muşmula ve ayvada sap kopması, delikler, çürükler, çatlaklar gibi bir yara ya da doğal açıklıklara ihtiyaç duyan hasat sonrası patojendir. Sert çekirdekli meyvelerde (kiraz, erik, şeftali), küçük meyvelerde (üzüm, çilek, kivi) ve fındıkta da *penicillium expansumun* sebep olduğu maviküf rapor edilmiştir. Maviküf açık ten renginden koyu kahverengiye kadar dairesel lezyonlar olarak çürümüş ve sağlıklı dokular arasında belirli bir sınır çizerek ortaya çıkar. Yumuşak ve sulu olan çürümüş dokunun oluşturduğu çürük alan üzerinde mavi-yeşil spor kütleleri gözlemlenir. Enfeksiyon bölgesinden başlayarak çürük alan yaşlandıkça dışarıya doğru yayılan bir gelişim gösterirler. (Luciano-Rosario vd., 2020). *Penicillium expansum* mantarının büyümesi ve patulin üretimi için Islak ve serin koşullarda (15-27 santigrat derece sıcaklık aralığında) en verimli şekilde büyüdüğü gözlemse de optimum sıcaklık ve bağıl nem sırasıyla 25°C ve %90'dır (Larous, 2007).

Elmada mavi küf hastalığına sebep olan *penicillium expansum* mantarı meyve kabuğunun yaralanması ile ürün içine giren elmayı da içeren 21 farklı cinse ait bitki grubunda hastalık oluşturarak, depolanmış ürünlerde %50'ye varan kayıplara neden olabilen bir patojendir (Mari vd., 2002). Mavi küf hastalığı yumuşak çekirdekli meyve endüstrisi için büyük riskler getirir. Meyve kalitesini olumsuz etkileyerek taze meyve tüketimini azaltmakta, gıda kaybına ve büyük ekonomik kayıplara sebep olabilmektedir. Ayrıca ürettiği mitotoksinler sebebiyle insan sağlığına zararları bulunmaktadır. Patulin, sitrinin, chaetoglobosinler, komünler, rokfortin C, ekspansolidler A ve B, okratoksin A, penitrem A,

rubratoksin B ve penisilik asit toksin maddelerine sahiptir. Özellikle yaygın bir elma patojeni olan *Penicillium expansum* olmak üzere birçok mantar türü tarafından üretilen patulin meyvelerin bozulmasının yanısıra insan sağlığı için de büyük riskler taşır. İnsanlarda gösterdiği toksik etkileri mide bulantısı, kusma ve diğer gastrointestinal travma ve buna eşlik eden böbrek hasarını içerir. Ayrıca kronik patulin maruziyetinin kanserli tümörlerin oluşumunu tetiklediği ve genetik mutasyonlara, embriyonik gelişimsel kusurlara neden olduğu da çalışmalarla gözlemlenmiştir (McCallum vd., 2002).

Hasat öncesi ve hasat sırasında *Penicillium expansum*'a karşı etkili fungisidal maddeler kullanılarak enfeksiyonların kontrol altına alınması sağlanabilir. Temizlik ve sanitasyon süreçleri, depolama koşulları ve Hasar görmüş meyvelerin diğer meyvelerden ayıklanması *Penicillium expansum*'un neden olduğu çürümeyi kontrol etmek ve önlemek için kullanılabilir. Mantarın elmada sebep olduğu etki Şekil 1.'de verilmiştir. (Luciano-Rosario vd., 2020).



Şekil 1. *Penicillium expansum* ile enfekte edilmiş elma meyvesindeki mavi küf çürüğü. (a) *P. expansum*'un neden olduğu mavi küf belirtileri olan elma meyvesi. (b) Conidia'nın terminal olarak zincirler halinde taşındığı bir *P. expansum* conidiophor'un taramalı elektron mikrografi (SEM). (c) *P. expansum* conidia'nın SEM fotoğrafı

1.3. *Penicillium crustosum* Mantar Özellikleri

Penicillium crustosum, 1930 yılında Thom tarafından bulunup 1949 yılında varlığı Raper ve Thom tarafından elmalarda bozulmaya yol açtığı onaylanan, penicillium cinsine ait bir mantar türüdür.

Canlılarda sürekli titremeye sebep olan doğal bileşikler genelde birçoğu küfler tarafından üretilir. Bu duruma sebep olan toksinlerden en önemlisi olan ve canlılarda sinir sistemini etkileyen penitrem A toksininin en önemli kaynağı *penicillium crustosum*

mantarıdır. Penitrem A kan dolaşımına girdikten sonra kan beyin bariyerini geçerek beyine ulaşır nörolojik hastalığa sebep olmaktadır. İlk zamanlarda evcil hayvanlarda ortaya çıkan ve sinir sistemini etkileyen rahatsızlıklar sıklıkla diğer *penicillium* türlerine bağlansa da günümüzde bu hastalıkların temel nedeninin penitrem A mitotoksini olduğu bilinmektedir. Bu toksinler evcil hayvanların yanı sıra çiftlik hayvanları ve daha nadir durumlarda insanlarda titreme, kusma, hipertermi ve diğer sağlık sorunlarına neden olabilmektedir. Koyun, inek, at ve köpeklerde ölüme ve beyinde hasara sebep olduğu bilinmektedir (Roberts vd., 1996). Mantar, insan sağlığı için endişe verici olan mikotoksinler (penitrem A, roquefortine C, terrestrik asit ve siklopenol) üretmesinin yanı sıra meyvelerde maviküf hastalığına neden olan hasat sonrası bir patojendir (Duduk vd., 2021).

Penicillium crustosum subtropikal ve ılıman bölgelerde gıda ve yemlerde yaygın olarak bulunan bir mantar türüdür. Genellikle mısır, işlenmiş et ürünleri, fındık, et, peynir, yemler, sebzeler, elma ve çekirdekli meyveler ve sebzelerin toprak rizosferinde de bulunur (Sonjak, 2005).

Penicillium küflerinin arasında en hızlı gelişen türlerden biri olan mantar 30-40 mm çapında düz, yüzeyi pudramsı mavi-yeşil koloniler oluşturmaktadır. Mantar sporları grimsi yeşil, mavi yeşil, mat sarı yeşil veya mor renkte olup mikroskop altında bakıldığında düz duvarlı, küresel yapıda gözlenir.

Gıdalar ve yemlerde sıklıkla görülen *Penicillium crustosum* mantarı optimum 25 derecede gelişebilen bir küftür. Yüksek su aktivitesine sahip ortamlarda mitotoksin oluşturma özelliğine sahiptir. pH toleransı 2-10 arasında olduğu için Asidik ve bazik ortamda büyüeyebilirler (Meriç, 2001). Toprak, bitki artıkları, gıda ürünleri, gıda işleme tesisleri ve nemli ortamlarda yaygın olarak yetişebilirler.

Penicillium crustosum mantarı elmalarda maviküf çürümesine neden olmaktadır. Ürettiği mitotoksinler *P. expansum*'a göre daha az saldırgan bir patojen olmasına rağmen geniş bir alana dağılır (Duduk vd., 2021). Mitotoksinler uzun süreli depolama sırasında elma üzerinde çürümeye neden olmaktadır. Meyve çürümesi, yumuşama ve lezzet bozulması meyvede kalite kaybına sebep olur. Bu durum pazarlama ve tüketim süreçlerinde ciddi ekonomik kayba sebep olabilir.

1.4. *Aspergillus niger* Mantar Özellikleri

Aspergillus cinsinin Nigri bölümünde sınıflandırılan bir küf olan *aspergillus niger*, dünya çapında taze meyveler, tahıllar, mahsuller ve depolanan gıdalarda “siyah küf” hastalığına neden olan bir mantar çeşididir (Lima vd., 2019). Hızlı büyüme yeteneğine ve pH toleransına sahip, meyve, sebze, sert kabuklu yemişler, fasulye, tahıllar, şifalı bitkiler, odun ve bitkisel ilaçlar dahil olmak üzere çeşitli organik maddelerin çürümesine neden olmasını sağlar. *Aspergillus niger* bitkilerde hasat sonrası birçok çürük hastalığına sebep olur. Donuk veya koyu siyah görünümündedir.

A. niger diğer filamentli türlerle karşılaştırıldığında nispeten zararsız olmasına karşın İnsanlar *A. niger*'in havada, gıda maddelerinde ve depolanan diğer tüketim ürünlerinde bulunan sporlara ve bitkisel formlarına sıklıkla maruz kalmakta ve alerjik sorunlar yaşamaktadır. *A. niger* mikotoksinler de üretebilir. Mitotoksinlerin Yeterli miktarda solunması halinde genellikle bağışıklık sistemi zayıf olan bireylerde insanlarda aspergiloz gibi ciddi akciğer sorunlarına, karaciğer, böbrek, sinir sistemi, kaslar, cilt, solunum organları, sindirim sistemi, cinsel organlar vb. ile ilgili çeşitli rahatsızlıklara neden olabilir (Gautam, 2011).

Donma koşullarında ve çok sıcak havalarda gelişebilen ve 6 ila 47 ° C sıcaklık aralığında çoğalabilmesi sıcağa toleranslı olduğunu gösterir. Büyümesi için en uygun ph değeri 6 olmasına rağmen geniş ph aralığında da (1,5 ila 9,8 arası) üreyebilmektedir. Gelişmesi için en uygun su aktivitesi ve bağıl nem sırasıyla %0,97 ve %96-98 olması diğer *aspergillus* türleri ile karşılaştırıldığında nispeten yüksek büyüme su aktivitesine sahip olduğunu gösterir. Bu özellikler bu türün her yerde özellikle sıcak ve nemli yerlerde daha sık karşımıza çıkmasına sebep verir (Palacios-Cabrera vd., 2005).

Aspergillus niger endüstriyel süreçlerde (tekstil, ilaç, kağıt üretimi ve biyo-yakıt üretimi) gibi Hücre dışı (gıda) enzim üretiminde ve gıda sektöründe içeceklerden konserve gıdalara kadar birçok üründe kullanılan sitrik asit üretmek için uzun süredir kullanılmaktadır. *A. niger*, meyve işleme, fırınlama, nişasta ve gıda endüstrilerinde teknik yardımcı olarak iyi bilinen çeşitli enzimlerin kaynağı haline gelerek endüstriyel kullanıma da sahiptir. Bu sayede biyoteknolojide kullanılan en önemli mikroorganizmalardan biri haline gelmiştir. *Aspergillus niger*, tüm dünyada toprakta, suda, havada, çürüyen bitki materyalinde ve çok sayıda gıda ve yemde bulunan bir mantardır. *Aspergillus* cinsi mantar

spor hücreleri rengine göre gruplara ayrıldığında kahverengi ve siyah gölgeli sporlara sahip aspergilli *A. niger* grubunu oluşturur (Schuster vd., 2002).

Aspergillus çürüklüğü semptomlarını gösteren meyve dokularından çeşitli *Aspergillus* türleri izole edilip incelendiğinde bunlar arasında *Aspergillus niger*'in şiddetli semptomlara neden olduğu gözlenmiştir. Uzun süreli depolama sırasında elmalarda hasat sonrası görülen en önemli hastalıklardan biri *Aspergillus* çürüklüğüdür (Hasan, 2000; Kumpoun vd., 2003). *Aspergillus niger*in elmalar üzerinde çürüme ve bozulma, meyve yüzeyinde siyah veya koyu yeşil lekeler oluşturması, depolama koşullarının uygun olmadığı yerlerde raf ömrünü azaltması ve ürettiği mitotoksinlerin hem insan sağlığı açısından hem de pazarlama ve tüketim alanında oluşturacağı ekonomik kayıplardan ötürü zararlar verebilmektedir.


1.5. Biyolojik Burun

Koku alma sistemi geçmiş çağlardan itibaren evrensel olarak kritik bir fizyolojik sistemi temsil eder. Koku alma sinyalleri üretildikten sonra koku alma bilgisi koku soğanında kodlanarak beyindeki çeşitli alanlara yayılır. Koku almanın moleküler temelini daha iyi anlaşılmasını, Axel ve Buck tarafından koku alma reseptörlerinin keşfi sağlamıştır. Fakat Koku alma sistemi tarafından kullanılan mekanizmaların, muazzam sayıda kimyasal olarak çeşitli koku moleküllerinin beyin tarafından anlaşılan sinyallere nasıl kodlandığını anlamının karmaşıklığından dolayı bu sistem hala tam olarak çözümlenememiş ve bu konudaki araştırmalar hala devam etmektedir. Kemosensasyon koku alma işlevinin en kritik işlevlerinden biridir. Diğer memelilere göre kemosensör girdiye daha az bağımlı olan insanlarda koku alma mekanizması çevredeki tehlikelerin tespitine, beslenme, cinsellik ve ruh hali de dahil olmak üzere zevk almada oynadığı rol gibi işlevleri üstlendiği için insan fizyolojisinde hala kritik bir rol oynamaktadır.

Gıda tercihleri, akraba tanıma ve çiftleşme, anne- bebek bağı, feromon tespiti hatta yaşam süresinin uzaması ve yaşam kalitesi gibi çok çeşitli fizyolojik süreçlerde koku almanın rolü olduğuna dair çalışmalar mevcuttur. Diğer duylarda olduğu gibi koku alma yeteneği de yaşlılık ve hastalık durumlarında azalır. Koku alma mekanizmasının sınırları hala tam olarak keşfedilememiştir. İnsan fizyolojisinin kritik ve ilginç bir işlevi olan koku alma mekanizmasını etkileyen klinik ve moleküler faktörlerin araştırılması koku alma bozukluğuna yönelik tedavilerin geliştirilmesine olanak sağlayabilir.

1.6. Burnun Yapısı

İnsan burnu kemik, kıkırdak, kas ve bağ dokusundan meydana gelir. Burun deliği girişinden arkadaki nefes borusu başlangıcına kadar uzanan boşluk orta hatta nazal septum tarafından ikiye ayrılır. Nazal septumun ön kısmı kıkırdaktan, arka kısmı ise kemikten oluşur. Burun yan duvarlarında alt, orta ve üst olmak üzere konkalar yer alır. Burun girişinde yer alan nazal valv; üst lateral kıkırdağın alt sınırı, septum ve alt konkanın ön kısmı tarafından oluşturulur. Bu alan solunum yolları direncinin en yüksek olduğu kısımdır. Bir madde burun ile koklandığında hava, alt konka üzerinden buruna geçer ve türbülanslı hava akımı ile bu epitelyuma doğru yukarıya doğru taşınır. İnsanda burun boşluğunun genel yapısı Şekil 2.'de verilmiştir (Pinto, 2021).



Şekil 2. Burun Boşluğunun Genel Yapısı

Burundaki sinir sistemi karmaşık mekanizmaya sahiptir. Burundaki kemosenstasyona aracılık eden koku siniri ve trigeminal sinirdir. Şekilde gözüktüğü üzere koku alma nöroepitelyumu, aksonları burun boşluğunun çatısındaki plaka boyunca çıkıntı yapan ve burada merkezi koku alma sinir sistemindeki sinaps yaptıkları koku alma nöronları ile etkileşime giren varlığı ile karakterize edilir. Koku alma nöronları mavi düğmelerle gösterilmiştir. Aksonlar ile koku alma soğanında sinaps yapar ve sonra merkezi sinir sisteminde ilerler. Koku alma epitelinin yeri insanlar arasında değişkendir. Yaşla birlikte koku alma nöronlarının kaybı, potansiyel olarak çevresel etkilere (toksinler, uçucu

kimyasallar, tütün dumanı), endüstriyel veya mesleki veya havadaki kirleticiler) veya enfeksiyon veya iltihaplanma gibi patofizyolojik süreçler gibi etkenlerle zamanla değiştiği düşünülür.


Koku alma işlevine ek olarak, burnun diğer ana kemosensör bileşeni trigeminal sistemdir. Burundaki trigeminal kemosensör sinir uçları, hava yolunun zararlı uyarılara karşı ilk savunma mekanizmasını oluşturur. Trigeminal sinirin dalları burun ve sinüslerin mukozasını aktive eder ve tahriş edici tepkilere aracılık eder Trigeminal kemosensör uyarılara verilen yanıtlar arasında ağrı, tahriş, hapşırtma, gözyaşı, burun salgısı, terleme, azalmış solunum hızı ve yer alır. Tahriş edici maddeler alt solunum yollarına ulaşırsa, alt solunum yolundaki benzer tepkiler duyuşal aktiviteyi tetikleyerek çeşitli tepkiler verir. Tahriş edici reseptörler hakkında koku alma reseptörlerinden çok daha az şey bilinmektedir (Pinto, 2001).

1.7. Koku Alma Prosedürü

Tüm canlı organizmalar doğada bulunan kimyasal işaretlere tepki veren mekanizmalara sahiptir (Özsandıkcioglu, 2016). Kimyasal işaretleri karşılayan; beslenme, konumlandırma yeteneği, gün ışığı, sıcaklık, koku veya canlı yaşamında tehdit unsuru oluşturabilecek çevresel koşulları algılamak canlılar için oldukça önemlidir. İnsanlar kokulardan geçmiş çağlardan günümüze kadar dinsel, hastalıkların teşhisi ya da güzel kokma isteği gibi çok çeşitli kullanım amaçları için yararlanmıştır (Uçar, 2013) koku alıcı reseptörlerden oluşan biyolojik koku algılama mekanizması tüm canlılarda ortak olarak bulunur. Bu mekanizma sayesinde canlılar koku yayıcılar tarafından havaya yayılan, organik asitler, aldehitler, alkoller, amitler, esterler, organik asitler, aminler, eterler ile karışık gazlar, ketonlar, hidrokarbonlar, nitriller, fenoller, nitrojen ve sülfür içerikli bileşiklerden meydana gelen uçucu organik bileşenlerini algılayıp, farklı koku modellerini tanıyabilir ve ayırt edebilir (Kablan, 2018).


Canlıların ihtiyaçlarına göre şekillenen Biyolojik koku algılama sistemi her canlı türünde farklılık göstermektedir. İnsanlarda bulunan biyolojik koku alma sistemi sayesinde yaklaşık olarak 10.000'in üzerinde farklı koku molekülü birbirinden ayırt edilebilir (Kablan, 2018).

İnsanlardaki koku algılama sistemi tüycükler (silya), hücre gövdesi ve akson uzantısı olarak 3 ana bölümden meydana gelir. Şekil 3.'de koku alma sisteminin genel yapısı gösterilmektedir (Özsandıkciğlu, 2016).



Şekil 3. Koku alma sistemi genel yapısı

Bir madde burun ile koklandığında maddenin kokusu burun boşluğunun üst kısmında bulunan ve mukus salgısı ile kaplı olan koku epiteli yardımıyla insanlar tarafından algılanır. Koku molekülleri koku epitelinde bulunan koku alma nöronların kirpik gibi uzantıları üzerindeki spesifik reseptör protein hücrelerine tutunur. Reseptör hücreleri özel yapıdadır ve koku molekülleri reseptör hücrede bu kokuya duyarlı olan ve olmayan molekülleri etkileyerek, kokuya özgü tepkilerin verilmesini sağlar. Koku nöronlarının akson uzantıları ile alınan bilgi koku soğancığına iletilir ve alınan sinyaller burada yoğunlaştırılır. Alınan sinyaller belirli işlemlerden geçerek koku bilgisinin beyine ulaşması sağlanır. Karar verme mekanizması olan beyinde anlamlı koku bilgisi oluşur (Kablan, 2018). Şekil 4.'de koku alma sistem mekanizması gösterilmektedir.




Şekil 4. Koku alma sistem mekanizması

1.8. Elektronik Burun Yapısı

İnsan burnu gıda, içecek, parfüm, kozmetik, kimyasal ürünlerin kalitesini ölçmek gibi birçok endüstride analitik araç olarak kullanılan önemli bir mekanizmadır. Duyusal panel olarak düşünülerek bir grup insanın analiz edilen maddeyle ilişkili kokulara ilişkin anketleri doldurduğu; bu şekilde kaliteyi koku yoluyla değerlendirdiği bir araçtır. Fakat insan koku değerlendirmesi gerek bireysel farklılıklardan kaynaklı, gerekse fiziksel, zihinsel sağlıktan ötürü birçok bireysel faktörden etkilendiği için duyusal panel olarak kullanıldığında sübjektif sonuçlar vermemektedir. İnsan duyu organlarının koku algılayarak ürün kalitesini değerlendirmesi ve tanımlamasına yardımcı olmak ve daha tutarlı sonuçları elde edebilmek için gaz kromatografisi ve kütle spektrometrisi kullanılmıştır. Fakat bu tekniklerin taşınabilir olmaması, pahalı olması ve performansların nispeten yavaş olmasına çözüm olarak geliştirilen elektronik burun teknolojisidir. Elektronik burun sistemleri parmak izi tanımlaması gibi koku moleküllerine özgü tepkiler verir. Bu olayı gerçekleştirmek için içindeki kimyasal sensör dizisini kullanarak desen tanıma yazılımı, koku tanımlama ve ayırt etmeyi gerçekleştirir. Duyusal paneller, kromatografik ve kütle spektrometrik tekniklerle ilgili sorunlara uygun maliyetli çözümü, taşınabilir olması ile tercih edilir (Arshak vd.,

2004). Şekil 5.'de elektronik burun ve biyolojik burun koku alma sistemlerinin karşılaştırılması verilmiştir.



Şekil 5. Elektronik burun ve biyolojik burun koku alma sistemleri karşılaştırılması

Elektronik Burun'da biyolojik burunda bulunan ise koku algılayıcılarının yerini kimyasal sensörler, koklama soğanını ve beyinin yerini yapay sinir ağları alır (Öztürk, 2008). Elektronik burunun çalışma sisteminde ilk aşamada koku örneği ortamdan izole edilmiş ve havası temizlenen sensör kabına pompa vasıtasıyla aktarılır. Sensör kabında bulunan sensörlerin her biri farklı seçiciliğe sahiptir ve havada bulunan uçucu organik bileşiklerle tepkimeye girerek sensörler üzerindeki elektriksel değerlerin (akım, frekans, direnç, gerilim vb) değişimine yol açarlar. Sensörlerden gelen işaret sinyalleri bilgisayara kaydedilir. Kayıt edilen işaret sinyallerde karmaşıklıktan kurtulabilmesi için üzerinde filtreleme, yükseltme, fark alma, normalize etme vb ön işlemler yapılır. İşlenen sinyaller örüntü tanımaya uygun olan algoritmaların seçilmesi ve uygulanması ile anlamlı koku bilgisi kazanılmış olur (Kablan, 2018). Elektronik burun ile insan burnu parametreleri karşılaştırılması Tablo 1'de gösterilmiştir (Şahin, 2008).

Tablo 1. Elektronik burun ile insan burnu parametreleri karşılaştırılması


Tanımlayıcı	Elektronik Burun	İnsan Burnu
Algılayıcı	Sensör	Alıcı Nöron
Aktiflik	Kaplama	Koku alma genleri
Algılayıcı Sayısı	6-30 sensör dizisi	10.000.000 reseptör
Sinyal İşleme Modülü	Mikroişlemci	Glomeruli
Tanımlama Modülü	Bilgisayar	Beyin
Duyarlılık	Ppm	Ppt
Seçicilik	<50 koku	10000-2000 koku

1.8.1. PEN3 Elektronik Burun

PEN3 metal oksit gaz sensörleri içeren taşınabilir elektronik burun çeşididir. Bireysel gazlar veya gaz karışımlarını ayırt edici özelliklerine göre tanımlayarak olumlu, olumsuz, iyi, kötü şeklinde hızlı ve basit dijital yanıtlar oluşturmasının yanı sıra niteliksel özellikler için eğitimle veya veri tabanı ile karşılaştırarak sonuç vermektedir. Bu şekilde sınıflama ve tanımlama işlemini gerçekleştirmeye olanak sağlar. İçerdiği özellikler sayesinde gaz akışı kontrolü ile birlikte değişen konsantrasyonlar ve analitik koşullar altında gazların niteliklerine göre oluşan desenlerin sabit kalabilmesine olanak tanır. Desen tanıma algoritmalarının çeşitli olması sayesinde Laboratuvarlar ve endüstriyel alanlar dahil bir çok alanda uygulama alanına sahiptir.

Hassasiyeti yüksek sensörlere sahip oluşu, küçük, hızlı, taşınabilir olması, bilgisayarla veya bağımsız modda çalışabilme, veri kaydetme özelliğine sahip oluşu ve çevrimdışı analiz yapabilme özellikleri kullanım açısından tercih edilebilirliğini artırır.

Yağların ekşimesi, gıdaların tazeliği, ambalaj malzemelerindeki koku, tatların bozulması, tıpta kötü koku, içeceklerdeki reçinelerin veya aromanın karakterizasyonu gibi alanlarda kalite kontrolünü sağlamaktadır. Şekil 6.' da PEN3 elektronik burun gösterilmiştir.



Şekil 6. PEN3 Elektronik Burun

Cihazda kullanılan sensörlerin çalışma sıcaklığı 350-500 derece arasındadır. Tek kalın film içeren 10 farklı metal oksit sensörü opsiyonel olarak ayarlanabilerek farklı uçucu gazlara farklı tepkiler verebilir. Sensör tepki süresi 1 saniyeden az olmakla birlikte ölçüm süresi işleme bağlı olarak 4 saniyeden birkaç dakikaya kadar sürebilmektedir. Ortalama 1 dakika ölçüm süresince 20 saniye ölçüm yapıldıktan sonra 40 saniye gaz verilmeyerek ölçümlerin sağlıklı şekilde gerçekleştirilmesi sağlanır. Örnek akış hızı ayarlanabilir olup 10 ml/dak ile 400 ml/dak arasındadır. Akış sisteminde dahili pompalar ve dahili numune seyreltme sistemi bulunur. PEN3 elektronik burunun çalışacağı ortam sıcaklığı 0 ile 45 derece arasında ve %5 ile %95 bağıl neme sahip olmalıdır (PEN3 datasheet). Tablo 2.' de PEN3 Elektronik burunda kullanılan sensörler verilmiştir.

Tablo 2. PEN3 Elektronik Burunda Kullanılan Sensörler, Zhao,2022

Sensör No	Duyarlılık	Ölçülen Gaz	Algılama Hassasiyeti
W1C	Aromatik Bileşikler	Metilbenzen	10
W3C	Aromatik Bileşikler (Özellikle Amonyak)	Benzen	10
W5C	Aromatik Bileşikler (Alkanlar gibi özellikle nispeten küçük polariteye sahip)	Propan	1
W1S	Metana karşı hassasiyet	Metan	100
W2S	Etanole karşı hassasiyet	Karbonmonoksit	100
W3S	Yüksek konsantrasyonlu alkanlar (Özellikle Metan)	Metan	100
W5S	Nitrojen oksitlere karşı hassasiyet (özellikle negatif yüklü hidrojen oksitler)	Nitrojendioksit	1
W6S	Hidrojen	Hidrojen	100
W1W	Sülfidler ve organik sülfidler	Hidrojen sülfid	1
W2W	Aromatik bileşikler ve organik sülfidler	Hidrojen sülfid	1

1.9. Elektronik Burun Uygulama Alanları

Elektronik burunun gelişim sürecinde ilk olarak 1961 senesinde yapılan doğal koku alma sürecini taklit ederek kokuları saptamak, tahmin etmek ve sınıflandırmak için nesnel bir araç sağlayan mekanik bir aletin geliştirilmesi dikkat çekmektedir. Koku sınıflandırması için akıllı bir kimyasal dizi sensör sistemi kullanılan elektronik bir burun kavramı, Persaud ve Dodd tarafından 1982 yılında İngiltere'deki Warwick Üniversitesi'nde ortaya atılmıştır. Elektronik burun 1987'de bir konferansta terim olarak geçerken, bu konuyla ilgili ilk konferans 1990'da yapıldı (Gardner ve Bartlett, 1994).

1985 yılında yapılan çalışmada akciğer hastalıklarının tespiti için hastaların solunan havasından alınan 12 numunenin ve 17 kontrol numunesinin, özel olarak geliştirilmiş bir nefes toplama tekniği ve bilgisayar destekli gaz kromatografisi/kütle spektrometrisi (GC/MS) kullanılarak, hastalıkla ilişkili gibi görünen birkaç uçucu organik bileşik tespit edilmiştir (Gordon vd., 1985). 1988 yılında ise akciğer kanserini saptamak için insan tarafından solunan hava bileşenlerini 16 kimyasal sınıfa sınıflandırarak bilgisayar tabanlı tarama tekniği geliştirilmiştir (O'Neill vd., 1988). Williams ve Pembroke ise kendilerine gelen bir hastanın dikkatini çeken köpeğinin hastanın vücudundaki diğer benlere hiç ilgi göstermeyip, sıklıkla günde birkaç dakika dikkatle lezyonu koklayarak geçirmesi üzerine, bu cilt lezyonunun erken evre bir malin melanoma olduğunu tespit etmişlerdir. Sonuç olarak bir editöre eğitilmiş köpeklerin melanomalı hastaları lezyonları koklayarak tanıyabileceklerini bildirmişlerdir. Bu konunun üzerine giden araştırmacılar akciğer kanserinin teşhisinde elektronik burnun ayırt edilişini kullanarak özellikle 2000'li yıllardan sonra çok sayıda araştırma yapmışlardır (Williams ve Pembroke, 1989). Elektronik burun yiyecek ve içecek endüstrilerinde tanımlama, miktar belirleme, kalite kontrol gibi farklı uygulamalar için aktif ve önemli kullanıma sahiptir. Tüketicilerin sağlık ve yaşam tehlikeleri dikkate alındığında gıda ürünlerinin uygun kalitesi üretiminin ve dağıtımının her aşamasında ele alınması gereken temel konulardandır.

Elektronik burun hastalıkların teşhisi ve erken tanısında önemli bir rol oynamaktadır. Astım hastalığının tespit edilmesi için elektronik bir burnun insan nefesinden astım tanısı konmuş hastaları sağlıklı kontrollerle karşılaştıran ayrıca elektronik bir burnun farklı derecelerde astım şiddetini ayırt edip edemediğini ölçen bir araştırma yapılmıştır. Hafif astımlı on genç hasta, 10 genç kontrol, şiddetli astımı olan 10 yaşlı hasta ve 10 yaşlı kontrol 2 ila 5 dakikalık aralıklarla verilen nefesin iki kez örneklendiği bir kesitsel çalışmaya katıldı.

Koku izleri, lineer diskriminant analizi ile analiz edilmiş ve Çapraz doğrulama değerleri hesaplanmıştır. Sonuç olarak hafif astımlı hastaların koku izleri, genç kontrollerden ve şiddetli astımı olan hastalar, yaşlı kontrollerden tamamen ayırt edilebildi. Hafif ve şiddetli astımı olan hastalar daha az ayırt edilebilmiştir (Dragonieri vd., 2007).

Elektronik burun bakteriler yüzünden oluşan uçucu organik gazların varlığını tespit edebilen yapısı sayesinde idrar yolu hastalığının teşhisinde de kullanılmıştır. İdrar yolu hastalığında kullanılan mevcut klinik teşhisler biyokimyasal, immünolojik veya mikrobiyolojik yöntemlere dayanmaktadır. Ancak bu yöntemler operatöre bağlıdır, zaman alıcıdır, pahalıdır. Bu sebeple 45 şüpheli vakadan idrar yolu enfeksiyonunu tespit etmek için elektronik burun kullanılmıştır. Vakaların 31 örneği test, 14 örneği ise doğrulama seti olarak kullanılmıştır. Yapılan çalışma ile, elektronik burun teknolojisi kullanılarak idrar örneklerindeki enfeksiyonun erken tespit edilebilme potansiyelini göstermiştir (Kodogiannis vd., 2008).

Dünya çapında bulaşıcı bir hastalığa bağlı ölümlerin önde gelen nedenlerinden biri olan tüberküloz hastalığının tespiti için de elektronik burun kullanılmıştır. Yapılan çalışmada makine öğrenimi yöntemleriyle birlikte nefes verme yoluyla tüberkülozu teşhis eden elektronik bir burun uygulamasını amaçlanmıştır. Elektronik burun, verilen nefesi tüberküloz şüphelisi ve sağlıklı kişi olarak sınıflandırmıştır. Göğüs röntgeni görüntüleri kullanılarak göğüs hastalıkları uzmanı tarafından onaylandıktan sonra toplanarak oluşturulan veri setinde verilen nefesi eğitmek ve sınıflandırmak için makine öğrenimi yöntemleri kullanıldı. Destek Vektör Makineleri (DVM), Rastgele Orman ve XGBoost kullanılarak oluşturulan modellerde solunan nefes DVM için %92, XGBoost için %88.24, YSA için %94.87 ve Rastgele Orman için %84.24 doğruluk oranlarıyla sınıflanmıştır (Teixeira vd., 2017).

Kulak, burun ve boğaz enfeksiyonları ile ilişkili patojenleri tanımlamak ve sınıflandırmak için elektronik bir burnun kullanımını araştıran bir çalışmada kbb enfeksiyonu olan 90 hastadan 90 bakteriyel sürüntü örneği toplanmıştır. Kıyas yapılabilmesi için bu numunelerin bazıları, ticari bir elektronik burun ile hemen analiz edilirken, aynı enfeksiyon bölgesinden benzer sayıda sürüntü alınıp mikrobiyoloji kültürü ve duyarlılığı için gönderilmiştir. Elektronik burun teşhisi mikrobiyoloji teşhisi ile karşılaştırıldığında, toplanan örneklerin yüzde 88.20' sinde elektronik burun teşhisinin doğruluğu gözlemlenmiştir (Shykhon vd., 2004).

Elektronik burun çeşitli kanser türlerinin belirlenmesinde etkili bir role sahiptir. Meme kanseri teşhisi üzerine yapılan bir çalışmada kanserin nefesteki uçucu organik bileşikleri etkilediğini gözlemlenerek meme kanserli kadınlarda potansiyel yeni bir hastalık belirtici olan nefesteki uçucu organik bileşenler üzerinde çalışma gerçekleştirilmiştir. Çalışmada teşhisi konulan kadın hastalardan 201 nefes örneği alınmış ve biyopsileri iki patolog tarafından okunmuştur. Nefes testi meme kanserli kadınlar ile sağlıklı gönüllüler arasında %94.10 duyarlılık ve %73.80 özgüllük gösterdiği, çapraz doğrulamada ise %88.20 duyarlılık %73.80 özgüllük gösterdiği gözlemlenmiştir (Phillips vd., 2003). Baş ve boyun kanseri hastalarında ise elektronik burun aracılığıyla solunan nefeste uçucu organik bileşiklerin analizinin tanısal doğruluğunu araştırmıştır. Teşhis konulan 36 hasta test grubu iken kontrol grubu 23 sağlıklı insandan oluşmaktadır. Kullanılan elektronik burun dört farklı sensör tipinden oluşan 12 metal oksit sensörünü içermektedir. Çalışmadaki ana amaç, hastaların nefesindeki çeşitli uçucu organik bileşenlerin neden olduğu sensörlerdeki direnç değişikliklerinin modelini belirlemektir. Elektronik burnun %90 duyarlılık ve %80 özgüllükle ayırt edebildiği gözlemlenmiştir (Leunis vd., 2014).

Diyabet hastalığı erken teşhisinde uygun yollarla kontrol edilebilir fakat ileri bir aşamaya ulaştığında kalp hastalıkları, böbrek hastalıkları, körlük ve belden aşağısı felç gibi ciddi hastalıklara neden olabilen bir hastalıktır. Hastalığın erken teşhisi için verimli, kullanımı kolay ve hastalarda ağrıya sebep olmayacak yapay koku tanımayı taklit eden elektronik burnun kullanılması önerilmiştir. Diyabet hastalarının nefesinde rastlanan aseton kokusu hastalığın teşhis edilebilmesi için önemli bir fizyolojik metabolik işarettir. Yapılan bir çalışmada 18 şeker hastası ve 24 sağlıklı insanın nefes örnekleri toplanarak elektronik burun ile ayırt edilebilmesi hedeflenmiştir. Yemekten önce, yemekten yarım saat sonra, yemekten bir saat sonra ve yemekten 2 saat sonra 5 algılama elemanından oluşan koku sensörü dizisi ile hastaların nefesindeki aseton konsantrasyonu test edilmiştir. Sonuçlar, şeker hastalarının sağlıklı insanlardan başarıyla ayırt edilebileceğini göstermiştir (Ping vd., 1997).

Yapılan bir çalışmada elektronik burun sütün raf ömrünü belirlemek için kullanılmıştır. Ortam sıcaklığında ve 5 °C sabit sıcaklıkta depolanan sütün her bir numunesi farklı zamanlarda elektronik burun ile analiz edilmiştir. Sonuçlar elektronik burun tarafından oluşturulan ölçümün hem sütte bakteri üremesini hem de raf ömrünü tespit etmek için kullanılabileceğini göstermektedir (Labreche vd., 2005).

Kahve ile yapılan bir çalışmada 12 kalay oksit sensörü içeren elektronik burun kullanılarak 3 ticari kahvenin ve 6 farklı kavurma süresinin (0 dan 11,5 dakikaya kadar) arasında elektronik burun ile ayırt edilebilirliği gözlemlenmiştir. 3 ticari kahveden her birinden alınan 30 örnek ile 90 örneğin ayırt edilebilirliği için %89.90 başarı oranı elde edilirken, 0 ve uzun kavurma sürelerinde %100 grup sınıflandırılması elde edilmiştir. Sonuç olarak kalay oksit gaz sensörlerinin kahvenin hem harmanlama hem de kavurma seviyesi arasında ayırım yapmak için kullanılabileceğidir (Gardner vd., 1992).

Bal üzerinde yapılan çalışmalarda Saeed Faal vd. (2019) elektronik burnun farklı yüzdelerde (saf, %20 şurup, %40 şurup, %60 şurup ve %80 şurup) bala eklenen katkı maddesini tespit etme yeteneğini araştırmıştır. Elektronik burundan elde edilen verilerin analizinde temel bileşen analizi (TBA), hiyerarşik küme analizi (HCA), doğrusal diskriminat analizi (DDA) kullanmıştır.

Ülkemizde de elektronik burun alanında önemli çalışmalar bulunmaktadır. Doğu Karadeniz'e özgü yetişen çay bitkisinden elde edilen çay içeceklerinin çeşitleri arasındaki ayırımı yapılan çalışmada altı adet farklı çay türüne ait bilgidan oluşan bir veri tabanı oluşturulmuştur. Verileri sınıflandırmak için; Karar ağaçları, k-En yakın komşu, Doğrusal ayırım analizi, Destek vektör makineleri ve Sınıflandırıcı toplulukları algoritmaları kullanılıp en başarılı sonucun doğrusal ayırım analizi algoritması kullanılarak elde edildiği gözlemlenmiştir (Kablan, 2018).

Çay ile ilgili yapılan farklı bir çalışmada 13 gaz algılayıcı taşıyabilir bir elektronik burun sistemi ile düşük kalite, orta kalite ve yüksek kalite olarak derecelendirilen 64 çay numunesinin yarısı eğitim verisi, diğer yarısı test verisi olarak kullanılmıştır. Yürüyen bir fermantasyon bandı üzerinden çay kokuları alınmış ve yapılan sınıflandırmada %74,19 sınıflandırma başarımları elde edilmiştir (Tozlu, 2014).

Su ürünlerinin tazeliğinin belirlenmesi üzerine de birçok çalışma yapılmıştır. Yapılan bir çalışmada alabalık, çipura ve levrek kokularının bir haftalık depolama süresince Arduino mikroişlemci uyumlu MQ3, MQ4, MQ5, MQ8, MQ9 ve MQ135 sensörleri ile ölçülerek ve kayıt altına alınmıştır. Sensörler kullanılarak balıkların bozulma eşikleri elde edilmiştir. Çalışma sonucunda gıda kalite parametrelerinin belirlenmesinde hızlı, kolay ve düşük maliyetli çözümler getirebilmek için Arduinio mikroişlemci kullanılarak yapılan elektronik burnun başarıya ulaştığı gözlemlenmiştir (Yavuzer, 2021).

Modern tarımda önemli yere sahip olan meyve ve sebzelerin kalite tespitine elektronik burun teknolojisi büyük katkı sağlamaktadır. Yapılan çalışmalarda meyve ve sebzelerin

sınıflaması ve mantarların tespitinde elektronik burun tercih edildiği görülmektedir. Russo vd. (2013) yılında elektronik burun kullanarak soğan çeşitlerini sınıflamıştır. 4 soğan grubu arasında DFA yöntemini kullanarak %97.50' lik başarı oranı elde etmiştir. (Russo vd.,2013).

Farklı bir çalışmada ise 10 farklı metal oksit sensör kullanılarak domateslerin uçucu koku bileşikleri sayesinde olgunluk seviyelerinin elektronik burun ile tespit edilebilirliği gözlemlenmiştir. Elektronik burnun farklı olgunluk durumlarını olgunlaşmamış, yarı olgun, tam olgun ve fazla olgun ayırt edilebilirliği için temel bileşen analizi (TBA) ve doğrusal diskriminant analizi (DDA) kullanılan çalışmada DDA analizini kullanarak, farklı domates olgunluk durumlarını ayırt etmek ve sınıflandırmanın TBA analizinden daha doğru sonuçlar verdiğini ve bu yöntemin her bir ilgili gruptaki toplam örneklerin %100'ünü sınıflandırabildiği gözlemlenmiştir. 4 olgunluk seviyesinde her bir seviyeden alınan 20 örnek test için, farklı bir bahçeden 4 olgunluk seviyesinde her bir seviyeden alınan 10 örnek doğrulama için kullanılmıştır. Olgunluk seviyeleri çapına (uygulanan kuvvet sonucu uğradığı deformasyonun çapta yarattığı değişikliğe) ve rengine (yoğunluk, ton ve beyazlığına) göre belirlenmiştir (Gómez vd., 2006).

Özalp vd. (2016) yılında limon, elma ve şeftali meyvelerinin ayırımında elektronik burun kullanarak eğitim ve test başarısı olarak %100 başarı oranına ulaşmıştır.

Araştırmalar aynı zamanda meyve hastalıklarının belirlenebilmesi için de elektronik burun kullanılabileceğini göstermiştir. Pan vd. (2014) hasat sonrası depolamadaki kayıpları engelleyebilmek için çilek ile çalışma yapmışlardır. Çileğe 3 farklı mantar tipi (*Botrytis* sp., *Penicillium* sp., *Rhizopus* sp.) enjekte etmişlerdir. Çilek meyvelerinin mantar enfeksiyonu tipinin dört grup için ayırt etme doğruluğu çok katmanlı algılayıcı sinir ağı modeli kullanılarak %96,6'ya ulaşmıştır. Bu çalışma ile elektronik burnun hasat sonrası depolama sırasında meyvelerdeki patojenik mantar tipinin doğru bir şekilde sınıflandırılmıştır. Ayrıca mantar hastalığının erken teşhisi gerçekleştirilmiştir (Pan, 2014).

Qin vd. (2023) çileklerde küçük mekanik hasarları belirleyebilmek ve tespit edebilmek için özel olarak kalibre edilen dört metal oksit ve dört elektrokimyasal sensör grubu içeren elektronik burun kullanmışlardır. Destek Vektör Makineleri, k-En Yakın Komşuluk Sınıflama, Doğrusal Diskriminant Analizi, Naive Bayes ve alt uzay topluluğu gibi çeşitli modellerle doğrulamanın ardından GS-DVM yöntemi ile sınıflandırma başarısını %84 bulmuşlardır. Haghbin vd. (2022) yaptığı çalışmada ise *Botrytis cinerea* mantarının kivide neden olduğu gri küfün erkenden tespit edilmesi için makine öğrenimi algoritmaları ile birlikte elektronik burun kullanmıştır. En yüksek sınıflandırma doğruluk oranının radyal

temel işlevli sinir ağı ile birlikte, mantardan etkilenmeyen ve etkilenen kivi örneklerini eğitim ve test veri kümelerinde sırasıyla %99.90 ve %100 doğrulukla sınıflandırdığı gözlemlenmiştir.

Modern tarımın en önemli ürünlerinden biri olan elmadaki mantarların tespiti teşhisi ve ayrımında az sayıda çalışma bulunmaktadır. Jia vd. (2019) yılında yaptığı çalışmada PEN3 elektronik burun kullanarak *Penicillium expansum* ve *Aspergillus niger* ile aşılansız taze ve küflü elmaları tespit etmeyi amaçlamışlardır, Elma örnekleri iki gruba ayrılmıştır. Sadece bir tür küflü/küfsüz aşılansız tek elma (tek örnek grubu, Grup A) ve aşılansız elmanın taze elma ile karışık elmaları (konserve örnek grubu, Grup B) toplandı. Grup A ‘nın eğitim ve test seti için %96,3 ve %90,0 başarı oranına, Grup B ‘nin ise eğitim ve test seti için %77,7 ve %72,0 başarı oranına ulaştığı gözlemlendi. Bu çalışma ile PEN3 elektronik burnunun sadece taze ve küflü elmaları etkili bir şekilde algılamadığını ve tanımadığını, aynı zamanda farklı kalıplarla aşılansız elmaları da ayırt edebildiği gözlemlenmiştir.


Guo vd. (2020) yılında yaptığı çalışmada *Penicillium expansum* tarafından elmadaki bozulma veya enfeksiyonun tespiti ve tahmini için elektronik burun kullanmıştır. Çalışma elektronik burun ile *Penicillium expansum* ile aşılama öncesi ve sonra elmanın gaz bilgilerini elde etmeyi ve elmada *Penicillium expansum* mantarının sebep olduğu üç farklı bozulma seviyesini tespit edebilmeyi hedeflemiştir. TBA-DA yöntemi ile eğitim setinin ve tahmin setinin doğruluğu sırasıyla %100 ve %97.22 ye ulaşmıştır.

Guo vd. (2021) yılında yaptığı çalışmada *Aspergillus niger*, *Penicillium expansum*, *Penicillium chrysogenum* ve *Alternaria alternata* dahil olmak üzere dört baskın mantarı elma örneklerine aşılansızdır. Ölçümleri dört farklı mantar çeşidi aşılansız örneklerin her bir mantar çeşidi için üç farklı bozulma derecesine sahip 30 elma örneği üzerinde gerçekleştirilmiştir. Her bir mantar çeşidi için bozulma yüzey alanına göre, 0,5-1 cm yarıçaplı numuneler birincil bozulma (Seviye 1), 1.0-1,5 cm yarıçaplı numuneler orta bozulma (Seviye 2), yarıçaplı numuneler 1,5–2,0 cm arası ciddi bozulma (Seviye 3), aşılansız taze elmalar boş grup olarak alınmıştır. Elmaların uçucu bilgileri PEN3 elektronik burun ile kaydedilmiştir. Mantarları ve bozulma derecelerini sınıflandırmak için Geri yayılım-yapay sinir ağları kullanılarak %95.62 ve %99.58'lik en yüksek tanıma oranlarıyla en iyi tanımlama modeli sonucuna sahip olduğu gözlemlenmiştir. Elektronik burun ile elma bozulmasının erken tespitinin gözlemlenebilirliği amaçlanmıştır (Guo vd., 2021).

Zou vd. (2022) yaptığı çalışmada ise elma kalitesi elmaların yüzeyinde bıçak yarası, kırık deri, ezilmiş yara, hastalık yarası, böcek yarası, çürüme veya büzülme görülmecek şekilde pürüzsüz ve pembe yüzeyli sağlıklı elmalar, elmanın yüzeyinde hafif cilt hasarı, bıçak yaraları veya donma görülür ve birkaç siyah nokta bulunacak şekilde zarar miktarı orta derecede olan elmalar ve elmanın yüzeyi zararlılar ve hastalıklar nedeniyle açıkça hasar gören, çürüme veya büzülmenin şiddetli şekilde gözlemlendiği elmalar olmak üzere üç gruba ayrılmıştır. Elma kalitesinin ayırt edilebilmesi ve sağlıklı elmaların tespiti için elektronik burun kullanılarak TBA-k-En Yakın Komşuluk Sınıflama-Destek Vektör Makineleri sınıflandırıcısının tanıma doğruluğu %96.45 iken Doğrusal Diskriminant Analizi- k-En Yakın Komşuluk Sınıflama -Destek Vektör Makineleri sınıflandırıcısının tanıma doğruluğu %97.78 başarı oranına ulaştığı gözlemlenmiştir. Qiao vd. (2022) ise yaban elmalarında yapay olarak olgunlaştırılan elmalarla doğal yollarla olgunlaşan elmaların ayırımı ve tespitini gözlemleyebilmek için elektronik burun kullanmışlardır. Meyve kalite indeksi olarak çözünür şeker içeriği, titre edilebilir asit içeriği, şeker-asit oranı, çözünür protein içeriği ve çözünür katı madde içeriği analizine dikkat edilmiştir. Elektronik burun sensörünün ürettiği sinyaller temel bileşen analizi (TBA), doğrusal diskriminant analizi (DDA), destek vektör makinesi (DVM) ve rastgele orman (RF) sınıflama şekillerinde analizleri yapıldığında en yüksek sınıflama doğruluğunun RF’de %98.30 olarak gözlemlendiği belirlendi.

1.10. Elektronik Burun Uygulamalarında Kullanılan Sensörler

Elektronik burunda algılayıcı birim kimyasal sensör dizisinden oluşmaktadır. Gaz sensörleri kullanım alanları açısından, büyük önem taşımaktadır. Kimyasal sensörler alınan bilgiyi akım değişimi, frekans değişimi, voltaj değişimi gibi farklı elektronik sinyal tipine dönüştürmek için dönüştürücüye ve aktif katmana ihtiyaç duyarlar. Sensörlerin performansı hassasiyet, seçicilik, tespit limiti, tepki süresi, uygun maliyet, hız ve süreklilik gibi özelliklere bağlıdır. Seçicilik sensörün özelliği dahilindeki belli bir gruba tepki verip diğerlerine tepki vermemesini ifade eder. Tespit sınır belli koşullar dahilinde sensör tarafından tespit edilebilecek numunenin en düşük konsantrasyonunu belirler. Tepki süresi ise sensörün tepki verebilmesi için geçen süre olarak tanımlanır. Bu özellikler ve küçük boyut, düşük güç tüketimi, kablosuz olma özellikleri sensörün tercih edilebilirliğini artıran faktörlerdir (Awang, 2014). Gaz sensörlerinin çalışma prensibi Şekil 7.’de verilmiştir.



Şekil 7. Gaz sensörleri çalışma prensibi (Kızıl, 2011)

Sensörler içerisinde iletken maddeler sayesinde ortamdaki fiziksel veya kimyasal değişimleri algılayıp koku moleküllerindeki kimyasal bileşenlerle etkileşime girerek tepkiler vermektedir Sensör tepkileri; sensör dizisine, gaz akışı hızına, kokunun kimyasal özelliğine, aktif sensör maddeleriyle kokunun reaksiyonuna, basıncına, ısı ve nem gibi birçok fiziksel parametreye bağlı olup, sensör çeşidine göre frekans, direnç, ısı ve kütle değişimi şeklinde veri sinyalleri üretilmektedir (Saraoğlu, 2008).

Elektronik burunda en çok kullanılan sensörler, avantajları ve dezantajları Tablo 3.'de belirtilmiştir (Pearce vd., 2006; Lu, 2022).

Tablo 3. Elektronik burunda en çok kullanılan sensörler, avantajları ve dezavantajları


Sensör Tipi	Ölçülen Büyüklük	Avantaj	Dezavantaj
MOS	İletkenlik	5–500 ppm arası çalışır. Düşük maliyet, kullanımı kolay	Yüksek test sıcaklığı, yüksek tespit limiti, zayıf seçicilik
İletken Polimer	İletkenlik	0.1–100 ppm arası çalışır. Kullanımı kolay, oda sıcaklığında kullanım	Neme duyarlı, zaman alıcı
Polimer	Kapasite	CMOS kimyasal algılayıcılara uygulanabilir	Neme duyarlı
Şotki Diyot	Gerilim	CMOS kimyasal algılayıcılara uygulanabilmesi ve entegre edilebilir	Platin, Altın, İridyum gibi yüksek maliyetli maddelere gereksinim duymaktadır.
Mosfet	I-V / V-C	1 ppm de çalışır. Düşük sıcaklıkta çalışma	Zayıf hassasiyet, yüksek test gereksinimi
Elektro katalitik	Akım	Elektriksel gürültüden etkilenmez	Dezavantaj olarak boyutu gösterilebilir.
Termokupl, Pelistör, Termistör	Sıcaklık	Ekonomiktir	Tepkime cevabını geç vermektedir.
QCM	Piazo-Elektrik	1 ppt de çalışır. Yüksek hassasiyet, hızlı yanıt	Uygulanması zor, zayıf sinyal-gürültü oranı
SAW	Piazo-Elektrik	1 ppb çalışır. İyi hassasiyet, hızlı tepki süresi	Sapmaya eğilimlidir.
SPR	Işığın kırılma değeri	Kullanıcı dostu teknolojiye sahiptir	Yüksek maliyetlidir
Floresans	Yoğunluk Değeri	1 ppb de çalışır. Hızlı ve iyi hassasiyete sahiptir.	Sınırlı aydınlatma kaynağına sahiptir. Işık değişimlerinden etkilenir
IR gaz sensör	Kızılötesi Spektrum	1 ppb de çalışır. Güçlü anti-parazit yeteneği, iyi stabilite	Zayıf hassasiyet

1.10.1. Metal Oksit Sensörler

Elektronik burunda kullanılan sensörler karşılaştırıldığında metal oksit sensörlerin hassasiyetinin yüksek oluşu, ekonomikliğı, kullanım kolaylığı, üretimsel çeşitlilik ve esnekliğı, yüksek sıcaklık veya zorlu durumlarda bu MOS'ların daha iyi stabilizeye ve tepki sürelerine sahip oluşu, doğruluk oranının yüksek olması ve modern elektronik cihazlara adaptasyonu açısından diğer sensörlere göre avantajlı kaldığı görülmektedir. Bu sebeplerden ötürü kullanım alanı geniştir ve gaz sensör endüstrisinin önemli kısmını oluşturur (İncegöl, 2022).


MOS tabanlı gaz sensörleri, çevresel izleme, yangın algılama, madenlerdeki zararlı gazların tespiti, ev güvenliğı, trafik güvenliğı ve sağlık hizmetleri gibi birçok uygulamada kullanılabilen sensör çeşididir (Goel, 2023).

Mos bazlı gaz sensörleri gazları ppt aralığında algılayabilirken, diğer sensör türlerinin yalnızca ppb veya ppm aralıklarında performans gösterebildiğini şekilde gösterilmektedir. Bazı sensör türlerinin çalışma aralığı Şekil 8.'de gösterilmiştir.



Şekil 8. Bazı sensör türlerinin performans göstergeleri

MOS sensörlerde en çok kullanılan algılama materyalleri ZnO, SnO₂, MoO₃, TiO₂, WO₃, NiO ve Cu₂O'dur. Gaz sensör uygulamalarında kullanılan metal oksit yüzdeleri Şekil 9.'da gösterilmiştir (Erenna, 2004).



Şekil 9. Gaz sensör uygulamalarında kullanılan metal oksit yüzdeleri

Çalışma sıcaklığı göz önünde bulundurulursa MOS iki kategoriye ayrılır. Düşük ile orta sıcaklıklarda ($<600^{\circ}\text{C}$) çalışabilen ve yüzey iletkenlik etkilerini takip eden malzemeye sahip olan Popüler MOS, SnO_2 ve ZnO birinci kaategoriye girer. Düşük sıcaklıkta toplu iletkenlik etkisi yavaş olan ve yüzeylerdeki oksijenin adsorpsiyonu ve uzaklaştırılması nedeniyle iletkenlikte değişiklik meydana getiren sensörlerdir. Çok yüksek sıcaklıkta ($>700^{\circ}\text{C}$) çalışan kütle iletkenlik etkilerini takip eden malzemeleri içeren TiO_2 , Nb_2O_5 ise ikinci kategoriye girer. Bu sensörler sadece yüksek sıcaklıkta çalışarak kısmi oksijen basıncındaki değişime yanıt vermektedir (Mooseley, 1992).

Mos ticari sensörler, dış kısmı metal oksitle kaplı ısıtma bobini içeren seramik bir silindirin (9,5 mm uzunluğunda, yaklaşık $\varnothing$ 3 mm) bir tutucuya monte edilmesi ile oluşur. Metal oksidin tanımlanmasını sağlayan katman çeşidi ince veya kalın olabilir (James, 2004).

MOS tabanlı gaz sensörleri sensörle temas eden hedef gaz sebebi ile elektriksel özelliklerde meydana gelen değişiklikleri kaydederek gazların varlığını algılayan, farklı gazların teması ile sensörün iletkenliğinin ve çalışma fonksiyonunun önemli ölçüde değiştiği sensörlerdir. Hedef gaz molekülleri ile temas ettiğinde, Algılayıcı malzemelerden elektronlar yakalanır. Çalışma sıcaklığına göre çeşitli türde oksijen iyonları (O^{-2} , O^{-} ve O_2^{-}) oluşması ile malzeme içinde bulunan yüzey elektron yoğunluğundaki değişime bağlı olarak algılama materyalinin iletkenliği/dirençleri değişir.

MOS baskın yük taşıyıcılarının elektronlar (ZnO , SnO_2 , TiO_2 gibi malzemeler) veya delikler (CuO ve NiO gibi) p tipi malzemeler sınıflandırılabilir yarıiletken malzemeleri içerir. N tipi Mos Metal oksit yüzeyinin hidrojen, etanol, aseton gibi indirgeyici gazlarla etkileşime girdiğinde direnç değerinde azalma gösterirken, p tipi malzemelerde direnç değerinin artışı gözlemlenir. Fakat ozon ve karbondioksit gibi oksitleyici maddelere maruz kalma durumunda n tipi mosların elektrik yoğunluğu azalması ile direnç değerinin artışı gözlemlenirken, p tipi mosta direnç değeri azalır (Goel, 2023; Zappa, 2018).

1.10.2. Metaloksit Yarı iletken Alan-Etkili Transistörler [MOSFET] Sensörler


Mosfet tabanlı koku algılama cihazları havadaki uçucu organik gazların (VOC) katalitik bir metalle temas etmesi sonucu metalde etkileşim oluşturabileceği prensibine dayanarak oluşturulmuştur. Mosfet'in kapısı ile cihazın elektriksel özelliklerindeki değişim incelenerek reaksiyonun sonucu algılanır. Metal katalizörün tipi ve kalınlığı değiştirilerek ya da farklı sıcaklıklarda çalıştırılarak cihazın duyarlılığı ve ayrıştırıcılığı optimize edilebilir (Nagle, 1998).

Mosfet sensörleri metal yalıtkan yarı iletken yapıya sahip olmasının yanı sıra algılama aralığı olarak ppm bölgesinde seçicilik gösterebilen sensör çeşididir. Yalıtkan özelliği sağlamak için genellikle MOSFET 'lerde kullanılan madde SiO_2 'dir. MOSFET'in birçok çeşidi olmasına karşın (ISFET, OGFET, SGFET vb.) elektronik burun uygulamalarında standart Mosfet konfigürasyonu yaygın olarak kullanılır. N tipi ortak kaynak konfigürasyonlu transistör kaynak, drenaj ve kapı olmak üzere üç kontakla çalışır. Genelde Pt veya Pd maddesinden oluşan fakat farklı metallerin de kullanılabildiği metal kapıya uygulanan gerilim ile drain-source arası akımı belirler. Gaz algılama için kullanılan kanal bölgelerinde kullanılan madde yapılarına göre mosfet çeşitleri n ve p kanallı olarak sınıflandırılabilir. MOS sensörlerden çok daha düşük sıcaklıklarda (yaklaşık 150 C) çalışabilen yapıya sahip oluşu ve standart mikroelettronik teknikler kullanılarak 1,5 mm x 1,5 mm kalıp boyutları üretilebilmesi açısından avantaja sahiptir (James, 2004).

Mosfet sensörleri sıcaklık, basınç, nem, ışık, manyetik alan ve gaz gibi birçok farklı fiziksel büyüklüğü ölçmek için kullanılabilen geniş uygulama alanı, kısa yanıt süresi, iyi seçicilik ve küçük elektriksel değişiklikleri yüksek hassasiyetle algılayabilen, doğrusal yanıt, küçük sensör boyutu, düşük maliyet, kolay entegrasyon yeteneği ve dayanıklı malzemelerden yapılması açısından avantajları bulunsa da yüksek güç tüketimi, kontrollü

ortam ihtiyacı, temel sapma, amonyak ve karbondioksit'e karşı düşük hassasiyet gibi dezavantajlara sahiptir (Sanaeifar, 2017).

Yüksek hızlı anahtarlama ihtiyacını karşılayarak akım kontrollü değil gate bacağına uygulanan gerilim (VGS) ile kontrol edilirler. Yükseltme ve osilasyon üretme işlerinde ağırlıklı olarak kullanılan mosfetler Çalışma yapısı olarak Depletion (Azalan) ve Enhance (Çoğalan) olarak iki çeşit çalışma karakteristiğine sahiptir. Depletion tipli mosfetlerde gate bacağına uygulanan gerilim 0v olduğu zaman bile drain ve source uçları arasında kanal bulunduğu için iletken halde olurken enhance tipli mosfetlerde Gate terminaline gerilim uygulanması halinde aktif hale gelmektedir (Çetin, 2022). Şekil 10.'da mosfet çeşitleri gösterilmiştir.



Şekil 10. Mosfet çeşitleri

1.10.3. Optik Sensörler

Optik sensörler elektriksel dirençte değişiklik yaratan tipik sensör sistemlerinden daha karmaşık mekanizmaya sahip sensörlerdir (Wilson, 2009). Optik gaz sensörleri gaz türlerinin belirli dalga boylarında yaydığı optik absorpsiyon/emisyon saçılımını kullanma prensibi ile çalışır. Işık yayan eleman, foto algılayan eleman, gaz algılayan eleman, ışığa tepki veren gaz algılama elemanı, toplama için bir filtre optik gaz sensörlerinde kullanılan

temel bileşenlerdir. Optik sensörlerin hidrojen gibi yanıcı gazların algılanmasında uzun zamandır kullanıldığı bilinmektedir (Yunusa, 2014).

Optik sensörler uçucu gaz türünü algılayabilmek için ışığın geçirildiği ve alıcı tarafında ölçülen ışığın soğurulma, floresans, polarizasyon, kırılma indisleri, saçılma ve yansıtma gibi belirleyici özelliklerini tanımlayarak gazın içeriği hakkında seçicilik sağlar (Beyhan, 2021).

Optik sensörler lazer, kızılötesi (infrared) ve fiber optik sensörler olmak üzere üç ana başlıkta çeşitlendirilebilir. Fiber optik sensörler algılama katmanı, optik fiber ve alt tabakadan meydana gelir. Çevresel izleme uygulamaları için potansiyel aday olmasının yanısıra seçicilik, duyarlılık ve stabilite açısından yüksek olması açısından avantajlıdır. Ancak optik fiberin boyutundan dolayı minyatürleştirmede sınırlamalara sahip olması dezavantajıdır (Nazemi, 2019).

1.10.4. Piezoelektrik Sensörler

Piezoelektrik sensörler kristal malzemelere uygulanan mekanik etki sonucunda elektriksel potansiyel fark tepkisi oluşturması prensibine bağlı çalışır. Bu özelliğin yanısıra kristal malzeme üzerine uygulanan elektriksel potansiyel, malzemenin mekanik yapısını etkileyebilir. Piezoelektrik sensörlerin çalışma prensibinde kristal malzemelerin rezonans frekansının olması ve kütle değişimlerine son derece hassas olması sensörün ayırt ediciliğini sağlar. Sensörlerdeki kristal malzemelerin bu özellikleri sayesinde kristal malzeme üzerine eklenen materyallerin uçucu gazlar ile etkileşime girdiğinde, kristalin kütle ve rezonans frekansında değişiklikler meydana gelmesi sayesinde uçucu gaz tipleri tespit edilebilir (Oh, 2011).

QCM ve SAW sensörleri piezoelektrik sensörlerde geniş kullanıma sahiptir. QCM sensöründe iki elektrot arasına sıkıştırılmış ve algılama işleminin gerçekleşmesini sağlayan piezoelektrik kuvars kristali sayesinde kristalin yüzeyindeki kütle değişimine bağlı olarak salınım frekansı üretir. Kütle hassasiyeti ile kristalin kalınlığı orantılıdır. Bu sensörlerin frekansı levha kalınlığıyla orantılı değildir. SAW gaz sensörlerinde ise kristal alt tabaka üzerinde 2 adet Saw reflektör dizisi bir çift elektrotun bulunduğu bir boşlukla ayrılmıştır. Alt tabaka olarak kullanılan alanda LiNbO en yaygın kullanılan malzemedir. Sensör yüzey dalgalarının fiziksel özelliklerini ve genliklerindeki değişimi algılayarak bunun oluşturduğu çevresel değişikliklere bağlı ayırt edilmeyi sağlar. Yüksek hassasiyet, kısa tepki süresi,

kablosuz teknolojilerde kullanılabilirliği SAW gaz sensörlerinin avantajları arasında sayılabilir (Nazemi, 2019).

1.11. Örüntü Tanıma Birimi

İnsanın beyninin taklidi olarak düşünülebilen bilgisayarda anlamlı verilerin çıkarılabilmesi için eğitime işlemi gerekmektedir. Koku ilk defa verildiğinde oluşan sinyal tepkileri kokuya özgü olarak kaydedilmekte, ikinci bir koklatma işleminde ise sistem bu kokuyu tanımaktadır. Karar verici olarak tanımanlanan, bilgisayar ya da herhangi bir mikroişlemcinin bulunduğu ve yazılımın yüklendiği donanım ortamında örüntü tanıma birimi çeşitli algoritmaları kullanarak her koku tipine özgü kaydedilen elektronik sinyali yapay zeka yazılımı ile ayırt eder. Bu şekilde yeni bir koku örneği geldiğinde sınıflama işlemi işlemi ile koku belirlemede etkin rol üstlenir.

1.12. E-Burun Yazılım

1.12.1. İşaret İşleme Aşamaları

Sensörlerden elde edilen işaretler elektronik burun ile koku tanıma sistemlerinde analog dijital dönüştürme işleminden sonra sınıflandırılmak üzere bilgisayara gönderilirken geçirdiği işlemler Şekil 11.'de gösterilmiştir.



Şekil 11. İşaret İşleme ve Sınıflandırma Aşamaları

1.12.2. İşaret Koşullama Ön işlemler

Sensörlerden elde edilen işaretlere karışan, sensörlerden kaynaklanan ısı gürültü, elektriksel devrelerden kaynaklanan iletim gürültüsü, analog dijital dönüşüm esnasında

oluşan kuantalama gürültüsü ve sayısal işaret işleme esnasında oluşan gürültü işaretleri, sensör cevaplarının sapması sistemin performansı olumsuz yönde etkilemekte ve anlamlı cevap elde edilmesini zorlaştırmaktadır. Bu sebeple işaret koşullama ön işlemler biriminde sayısal filtreleme, veri setindeki değerlerin dağılımını düzenli hale getiren çeşitli normalizasyon işlemleri (Min Kuralı, Max Kuralı, Z Score, Medyan, Sigmoid) gibi adımlar kullanılmaktadır. Temel ön işlemler ile birlikte modelin başarısını ve performansını artırır.

1.13. Öznitelik Çıkartma

Öznitelik çıkarma işlemi verilerin yüksek doğruluk oranıyla sınıflandırılması için son derece önemlidir. Temel amaç veri setini belirli sınıflara ait olan ve diğer sınıflarda bulunmayan karakteristik bilgilerin tespit edilerek kategorilere ayrıştırılmasıdır. Her koku birçok kimyasal bileşik içerir ve bu bileşenleri ayırt edebilmek için kokuya özgü parametrelerin ayrıştırılabilmesi öznitelik çıkarma işlemine bağlıdır. Kokuyu ayrıştırabilmeyi sağlayan öznitelik çıkarma yöntemi ile sonraki örüntü tanıma algoritmasının etkinliğini sağlamak için daha az fazlalık ile kokulara ait farklı karakteristik özelliklerin seçilerek sensör yanıtından sağlam bilgi çıkarılması sağlanır. Literatürde sıklıkla kullanılan öznitelik çıkarma yöntemleri Fourier dönüşümü, Hilbert dönüşümü, dalgacık dönüşümü, güç spektral analizi, türev, integral gibi matematiksel işlemler veya en basitinden verinin minimum ve maksimum değerleri arasındaki farklar, oranlar olarak sıralanabilir (Beyhan ve Çetin, 2019).

1.14. Sınıflandırma

Sınıflandırma işleminde her koku tipine özgü kaydedilen elektronik sinyal yapay zekâ yazılımı ile ayırt edilir. Kokunun ne tip bir koku olduğu daha önce kaydedilen ve öğretilen bir yapay zekâ yazılımı ile belirlenmektedir. Özniteliğe göre çıkarım yapılır. Bunun yanında her özniteliğin ilgili örüntü çıkarımı yâda koku tipi ile doğru şekilde ilişkilendirilmesi gerekir. Kaydedilmiş örüntü ve çıkış bilgileri ile sınıflandırma yöntemleri eğitilir ve daha sonra otomatik olarak yeni gelen veri tipi sınıflandırılır.

Sınıflandırma yöntemi olarak elektronik burun çalışmalarında literatürde veri temel bileşen analizi (TBA), doğrusal diskriminant analizi (DDA) öznitelik çıkarım yöntemleri, K-En yakın komşuluk yöntemleri, destek vektör makinaları (DVM), rastgele orman, naive bayes sınıflandırması tercih edildiği gözlemlenmiştir.

2. YAPILAN ÇALIŞMALAR

2.1. Veri Seti Tanıtımı

Bu çalışmada 13.05.2022 tarihli Zhao vd. (2022) tarafından yayınlanan Electronic Nose Characteristics of Apples Infected with Different Fungi adlı veri seti kullanılmıştır. Bu veri seti esas olarak elektronik bir burun kullanılarak farklı mantarlar ve taze elmalar ile enfekte edilmiş elmalardan toplanan verileri içerir. Elektronik burun 8 sensör içerir. Bu veri setinde seçilen "Fuji" elmaları, Çin'in Gansu Eyaletindeki elma tarlalarından toplandı. 160 olgun elma seçilerek her grupta 40'ar adet olmak üzere A Grubu, B Grubu, C Grubu ve D Grubu olmak üzere rastgele 4 gruba ayrıldı; elmalara aşıl原因an mantar çeşitleri *Aspergillus niger*, *Penicillium expansum* ve *Penicillium crustozum* idi. Elma örnekleri steril tezgahda temizlenmek amacıyla %75 alkol ile ön işleminden geçirilmiş ardından oda sıcaklığında kurutulma işlemi gerçekleştirilmiştir. Daha sonra, mantar örneklerinin aşıl原因ıcı ile enjekte edileceği A, B ve C üç grubunun her bir elmasının dört yönünde dört delik açılmıştır. Delinmiş halkalara sahip örnek elmalar deliklerden 7 günlük kalıplarla aşıl原因mış ve deliklerin üzeri steril film ile örtülmüştür. Mantar küflerinin aşıl原因ıldığı elma örnekleri 1000 ml'lik bir behere yerleştirilerek üzeri plastik sargı ile kapatılmıştır. 5 gün boyunca 25°C'lik sabit sıcaklığa sahip bir inkübatörde tutulmuştur. Sağlıklı sonuçlar elde edilebilmesi için test işlemi öncesinde elma örnekleri kuluçka makinesinden çıkarılarak 30 dakika bekletilmiştir. Deney sonuçlarının doğru sonuçlar verebilmesi için elektronik burun kullanılmadan önce inert gazla temizlenerek artık gazların etkisi ortadan kaldırılmıştır.


Elektronik burun parametrelerinin ayarlanması için temizleme süresi 500s, toplama süresi ortalama 350s, örnekleme aralığı 1s, enjeksiyon akışı 150ml/dak belirlenerek 'Data/raw_data' dosyasında ham veri kaydedilmiştir.

Veri setindeki elma örnekleri öncelikle fresh, *Aspergillus niger* enfekte edilmiş elma, *Penicillium expansum* enfekte edilmiş elma ve *Penicillium crustozum* enfekte edilmiş elma örnekleri olarak her birinden alınan adet elma örneği 4 ayrı grupta toplandı. Farklı örnek grupları veya taze veya bireysel küf bulaşmış elma setlerinin deneysel elma bilgileri Tablo 4 'de listelenmiştir

Tablo 4. Veri Seti Değerleri

Örneklenen Grup	Örnekleme Sayısı	Örnekleme Süresi	Sensör Sayısı
Taze Elma	40	0-400	8
<i>Aspergillus Niger</i>	40	0-400	8
<i>Penicillium Crustosum</i>	40	0-400	8
<i>Penicillium Expansum</i>	40	0-400	8

Deneyde kullanılan taşınabilir elektronik burun cihazı elektrokimyasal sensörlerden oluşan sensör dizisi içerir. Kontrol ünitesi, sensör odası ve veri toplama ve aktarma ünitesi olmak üzere temel olarak 3 bölümden oluşan cihaz şekilde; şematik diyagram ise şekilde gösterilmiştir. Numune alma valfi, numuneden alınan gazın kapalı şişeye girişinin kontrolünü sağlar. Enjeksiyon valfi numuneden alınan gazın hava odasına giriş ve akış kontrolünü sağlar. Enjeksiyon valfi ve vakum valfi ise gaz örnekleri üzerinde dışardan gelen gazların etkisini kaldırmak için birlikte çalışarak dış gazlara engelleyici etki gösterir. Çalışmada kullanılan elektronik burun ve şeması Şekil 12.'de gösterilmiştir.



Şekil 12. Çalışmada kullanılan elektronik burun ve şeması

Deneyde sensörlerden elde edilen verilerin doğruluğunu test edebilmek için özdeş kullanılan iki sensörün (1 ve 5 numaralı sensörler) 150-300 saniye arasında verdiği tepkiler kaydedilerek karşılaştırılır. İki sensör tepkileri karşılaştırıldığında eğer aralarındaki fark 1,2 mg/L'den büyükse numune anormal kabul edilir ve eliminasyon işlemi gerçekleştirilir.



Tablo 4 de çalışmada kullandığımız ve elektrokimyasal sensör dizisi içeren taşınabilir elektronik burunda kullanılan sensörler gösterilmektedir. Tablo 2 ise PEN3 elektronik burunda en sık kullanılan metal oksit sensörleri içerir. Özellikler açısından karşılaştırıldığında elektrokimyasal sensörlerin tanıma açısından hassasiyetinin metal oksit sensörlerden daha fazla olduğu gözlenir. Çalışmada kullanılan elektronik burun sistemi taşıma açısından uygun kullanıma sahip olmasının yanısıra ekonomik olarak aynı fiyattaki elektronik burunlara göre daha düşük maliyete ve daha yüksek algılama doğruluğuna sahiptir. Hacmi yaklaşık 0,04 m³, ağırlığı ise yaklaşık 15 kg olması kullanımı kolaylaştıran etmenlerdendir (Zhao, 2022). Tablo 5.'de çalışmada kullanılan elektronik burundaki sensörler verilmiştir.


Tablo 5. Çalışmada Kullanılan Elektronik Burundaki Sensörler

Sensör Numarası	Sensör Modeli	Ölçülen Gaz	Algılama Hassasiyeti
1	7NE/C2H4-20	C2H4	0.4
2	7NE/H2S-50	H2S	1
3	7NE/H2S-1000	H2S	20
4	7NE/C2H4-200	C2H4	4
5	7NE/C2H4-20	C2H4	0.4
6	7NE/ETO-20	C2H4O	0.4
7	7NE/PID-300	VOC	6
8	7NE/CH2O-2000	CH2O	40


2.2. Sensör Tepkileri

Aşağıda ham veriden random şekilde seçilen *aspergillus niger*, *penicillium expansum*, *penicillium crustosum* mantarı enjekte edilmiş ve hiçbir mantar çeşidi enjekte edilmemiş elmalardan alınan örneklerin 8 adet sensöre verdiği tepkiler grafiksel olarak verilmiştir.





Şekil 15. *Penicillium Crustosum* 4. ve *Penicillium Crustosum* 20. örneğe ait sensör tepkileri



Şekil 16. *Penicillium Expansum* 4. ve *Penicillium Expansum* 20. örneğe ait sensör tepkileri

2.3. Öznitelikler

2.3.1. Ortalama

Sinyaldeki bir özellik ayarındaki değerlerin toplamının veri noktalarının sayısına bölünerek bir diğer deyişle sinyalin mutlak değerinin ortalaması alınarak elde edilen bir yöntemdir. Basit ve kullanışlı bir işlem olmasının yanısıra veri setindeki gürültüyü azaltmak ve ayırt ediciliği sağlayabilmek açısından etkili bir öznitelik çıkarma yöntemidir. s_k olarak nitelendiren bir sinyalde ($k = 1, 2, \dots, N$) N adet örneğe sahip bir sinyal için mutlak ortalama değeri aşağıdaki formüle dayalı olarak hesaplanır (Çalışkan, 2019). Matlabde fonksiyon olarak mean komutu ile gerçekleştirilir.

$$\text{Ort}(x) = \mu = \frac{1}{N} \sum_{k=1}^N |s_k| \quad (1)$$

2.3.2. Medyan

Medyan veri kümesi küçükten büyüğe sıralandığında ortadaki değeri alan bir istatistiksel hesaplama aracıdır. Veri setindeki örnekleme eleman sayısı tekse ortadaki değer, eleman sayısı çiftse ortadaki iki değer ortalaması medyan değerini bize verir. Ortalamadan farklı olarak aykırı değer etkilerini azaltır.

2.3.3. Varyans

Varyans veri setindeki değerlerin ortalama etrafındaki dağılımını gösteren istatistiksel bir ölçme biçimidir. Varyans değeri hesaplanırken öncelikle veri setindeki değerlerin aritmetik ortalaması hesaplanır. Daha sonra o anda alınan her ölçüm değerinin aritmetik ortalamadan farkı alınır. Farkların kareleri alınıp toplandıktan sonra bulunan toplam, veri noktalarının sayısına bölünerek varyans değeri hesaplanır. Varyansın karekökü standart sapmayı elde etmemizi sağlar. Varyans değerinin büyük çıkması öznitelik değerlerinin ortalama etrafında fazla dağıldığını, geniş bir dağılıma ve çeşitliliğe sahip olduğunu gösterirken, varyans değerinin küçük çıkması ise değerlerin ortalama değer etrafında yoğunlaştığını gösterir (Yağanoğlu, 2014; Turan, 2012). Matlabde fonksiyon olarak var komutu ile gerçekleştirilir.

$$Var(x) = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (2)$$

2.3.4. Standart Sapma

Standart sapma özniteliğin dağılımındaki ortalamaya göre değişkenliği ölçen, varyansın karekökü alınarak da hesaplanabilen ölçme biçimidir. Her bir veri değeri için aritmetik ortalamaya göre farkları alındıktan sonra bu farkın karesinin karekökü alınarak standart sapma değeri elde edilmiş olur. Standart sapma değerinin büyük olması veri setindeki değerlerin ortalama değerden uzak olduğunu ve veri setindeki değişkenliğin fazla olduğunu gösterir. Aksi durumda veri setindeki değerlerin ortalama değere yakın olduğu ve veri setinin homojen dağılım gösterdiği söylenebilir (Yağanoğlu, 2014; Turan, 2012). Matlabde fonksiyon olarak std komutu ile gerçekleştirilir.

$$Std(X) = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3)$$

2.3.5. İntegral

Bir sensör tarafından ölçülen fiziksel büyüklüğün (sıcaklık, hız, basınç) zaman içindeki değişimini gözlemleyebilmek için integralinin alınması bu büyüklüğün genel bilgisini anlamlandırabilmek adına çeşitli bilgiler sağlar. İntegral belirli zaman aralığındaki değişimleri ölçebilmek için fonksiyon altında kalan alanı ve fonksiyonun zaman içindeki toplam etkisini ifade eder. Veri setinden anlamlı bilgiler çıkarabilmek için zaman aralığındaki sinyaldeki değişimin kaydedilmesi farklı sinyallerin birbirinden ayırt edilebilmesi ve uygun desen oluşturabilmesi açısından fayda sağlar. İntegral kullanılarak sinyale özgü enerji, alan altındaki alan, toplam değişimi gözlemlenir.

Matlabde fonksiyon olarak trapz komutu ile gerçekleştirilir. Çalışmada sinyalin örnekleme frekansı 100 olarak belirlendiğinde kullanılan diğer öznitelikler ile en yüksek sonuç alınmıştır. Örnekleme frekansı ile süre hesaplanıp, zaman vektörü oluşturularak her değer için integral hesaplanmıştır. sk olarak nitelendiren bir sinyalde ($k = 1, 2, \dots, N$) N adet örneğe sahip bir sinyal için integral değeri aşağıdaki formüle dayalı olarak hesaplanır

$$\text{İnt}(Sk) = \int_1^N S_k \quad (4)$$

2.3.6. Diferansiyel

Veri setinde veya sinyalde ardışık örnekleme noktaları arasındaki farkın bulunmasıyla elde edilen diferansiyel fark veri setindeki değişimleri gözlemlemek için yapılan işlemidir. Diferansiyel farkın öznitelik olarak kullanılması ile veri setindeki durağanlıklar, iniş çıkışlar, değişimler, hız ve ivme durumları belirlenebilir. Her sinyal için farklı diferansiyel fark değerlerinin elde edilmesiyle desen oluşturma ve dinyallerin birbirinden ayırt edilmesi öznitelik belirlemek için yaygın olarak kullanılır.

Matlabde fonksiyon diff komutu ile gerçekleştirilir. s_k olarak nitelendiren bir sinyalde ($k = 1, 2, \dots, N$) N adet örneğe sahip bir sinyal için diferansiyel fark aşağıdaki formüle göre hesaplanır.

$$Y_k = S_{k+1} - S_k \quad (5)$$

Vektörel olarak;


$$Y = [S(2) - S(1), S(3) - S(2), \dots, (S_N) - (S_{N-1})] \quad (6)$$

Çalışmada matlabde diferansiyel farkların toplamı (sum(diff) komutu ile) ve diferansiyel farkın varyansı (var(diff) komutu ile) öznitelikleri diğer öznitelikler ile kullanıldığında en yüksek sonuç alınmıştır.

2.3.7. Gradient

Gradyan sayısal olarak fonksiyonun belirli noktalardaki bilinen değerleri temel alınarak tüm boyutlardaki kısmi türev değerlerinin tahmin edilmesiyle optimizasyonu sağlayabilmektir. Birçok makine öğrenimi algoritmasında optimazsyon genel bir problem olarak karşımıza çıkar. Optimizasyon çoğu makine öğrenimi algoritmasında var olan amaç olarak global minumum ve global maksimumu bularak öğrenmeyi daha iyi hale getirmeyi hedefleyen bir algoritmadır. Türevlenebilir bir f fonksiyonunun belirli parametrelerinde değişiklik yaparak minumum/maksimum değeri bulunmasıyla optimizasyon sağlanır. Gradyan iniş algoritmalarında ise. hata/kayıp fonksiyonu minumum yapılarak optimizasyon yapılmasıyla makine öğrenim algoritması iyileştirilir.

Gradyan iniş algoritması doğrusal olmayan programlamada ve türevlenebilir fonksiyonlarda kullanılabilir. Öğrenme hatasının azaltılabilmesi için model parametreleri güncellenir (Yağmur, 2020; Çakar, 2022). Şekil 17.'de gradyan grafiği gösterilmiştir.



Şekil 17. Gradyan grafiği

Gradyan iniş yönteminde fonksiyonun türevi temel alınarak eğimin + veya – olması durumuna göre minimizasyon için uygun konumun nereye taşınması gerektiği belirlenir.

1- $\frac{\partial f(x)}{\partial x_n} > 0$ durumunda türev değeri 0 dan büyük artan bir fonksiyon görülmektedir.

Optimizasyonun gerçekleşebilmesi için x azalan yönde hareket ettirilmeli ve konumu güncellenmelidir.

$$X_{n+1} = X_n - \gamma \frac{\partial f(x)}{\partial x_n} \quad (7)$$

$$X_{n+1} < X_n \quad (8)$$

2- $\frac{\partial f(x)}{\partial x_n} = 0$ durumunda türev değeri 0 dır ve minumum değere ulaştığı görülmektedir.

x değerinde herhangi bir konum güncellemesine ihtiyaç duyulmaz.

$$X_{n+1} = X_n \quad (9)$$

3- $\frac{\partial f(x)}{\partial x_n} < 0$ durumunda türev değeri 0 dan küçük azalan bir fonksiyon görülmektedir.

Optimizasyonun gerçekleşebilmesi için x artan yönde hareket ettirilmeli ve konumu güncellenmelidir.

$$X_{n+1} > X_n \quad (10)$$

Çalışmada matlabde gradyan değerlerinin maksimumu (max(gradient) komutu ile)ve gradyan değerlerinin ortalaması (mean(gradient) komutu ile) öznitelikleri diğer öznitelikler ile kullanıldığında en yüksek sonuç alınmıştır.

2.3.8. Bant Genişliği Özniteliği

Hızlı fourier dönüşümü sinyallerin istenilen frekans bandındaki frekans bileşenlerini analiz etmek için güçlü bir araçtır.

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-j2\pi(k-1)(n-1)/N}, k=0, 1, \dots, N \quad (9)$$

N örnekleme sayısını, X(n) giriş sinyalini, X(k) ise hızlı fourier dönüşümü ifadesini temsil eder (Aydemir, 2016).

Çalışmada ise belirli frekans bandındaki enerjiyi hesaplamak için veri setindeki örnek sinyallere öncelikle hızlı fourier dönüşümü uygulanmıştır. Fonksiyon için öncelikle veri seti, örnekleme frekansı, frekans bandının merkez değeri 5 ve frekans bandı genişliği 10 parametreleri belirlenir. Veri setinin boyut değerleri değişkenlere atanarak her bir sensör dizisinin tepkisinin enerjisi hesaplanmak üzere vektör oluşturulur. Sinyalin uzunluğu belirlenerek hızlı fourier dönüşümü uygulanır. Seçilen frekans bandının enerjisi hesaplanarak normalizasyon yapılır. Bu şekilde bant gücü hızlı fourier dönüşümü uygulanarak hesaplanır.

2.3.9. Dalgacık Dönüşümü

Dalgacık dalganın küçük bir parçası olarak tanımlanabilen, zaman olarak belirli sınırlara sahip titreşim işaretidir. Dalgacık analizi ile verilerin periyodik ve karakteristik yapısının tanımlanması sayesinde yapay sinir ağlarının başarı oranı artırmakta ve oluşan desenlerin birbirinden ayırt edilmesini kolaylaştırmaktadır. Verilerin zaman ortamında incelenmesinin yanısıra ölçeklendirilmesi ve frekans ortamında da incelenmesine olanak sağlayan bir analiz yöntemidir (Partal, 2008).

Durağan olmayan, karakteristiği zamanla değişen ve zaman ölçekli sinyaller için sinyalin daha küçük parçalar biçiminde alt frekans bantlarına ayrılarak incelenmesi ilk olarak 1984'te Grossman ve Morlet tarafından kullanılmıştır (Aydemir, 2016). Zamanla geliştirilerek Tıp da EKG ve EEG gibi biyoelektrik işaretler gibi birçok durağan olmayan işaretlerin analizinde ve öznitelik çıkarmada kullanılan en önemli metotlardan biri haline gelmiştir. Gürültüye karşı daha az hassasiyet göstermesi sebebiyle gürültü yok etme (işaretin veya görüntünün temizlenmesi) ve sinyali belli zaman aralıklarında sıkıştırılması başlıca uygulama alanlarını oluşturur.

Matematiksel temel olarak fourier dönüşümüne dayanmaktadır. Fourier analizi zaman ortamındaki işareti farklı frekanslardaki sinüslere ayrıştırarak frekans ortamına dönüştürür. Fourier analizi birçok açıdan kullanışlı olsa da frekans ortamına dönüştürdüğünde zaman bilgisi kaybolmuş olur. Durağan işaretlerde yani zamanla özelliği değişmeyen işaretlerde bu durum önemli olmasa da birçok işaret keskin geçişlere ve sürekli karakteristiğe sahiptir. Fourier analizi işarettaki incelecek kısmın başlangıç bitiş yerleri ve ani geçişleri algılamak için yeterli olmamaktadır. İşaretin küçük parçalara ayrılıp incelenebilmesi için kısa zaman fourier dönüşüm yöntemi geliştirilmiştir. Kısa zaman fourier dönüşümü işareti zaman ve frekans ortamında inceleyerek işaretin incelenecek kısmının hangi zamanda ve hangi frekansta olduğu bilgisini verir. Fakat zaman ortamındaki pencere boyutu değişirken frekans ortamındaki pencere boyutunun sabit kalması yöntemin dezavantajlı olduğu kısmı gösterir. Birçok sinyal daha kapsamlı analize ihtiyaç duyar. Pencere boyutu hem zaman hem frekans ortamında değişmesi gereken bir ögedir. Dalgacık dönüşümü Değişken büyüklüklerde pencereleme tekniği ile Fourier ve Kısa Zamanlı Fourier Dönüşümü'nün çözüm üretmediği zaman belirsizliğinin üstesinden gelerek, zaman serisi ve sinyal analizi yöntemlerine yeni bir yaklaşım getirmiştir. Dalgacık Dönüşümü, FD ve KZFD'nin aksine zaman-frekans bölgesi yerine zaman-ölçek bölgesini kullanır. Dalgacık dönüşümü ile ana dalgacık kaydırılarak zaman bölgesinde, ana dalgacık ölçeklendirilerek frekans bölgesinde işlem yapar. Bu sayede düşük frekanslarda uzun zaman aralıklı, yüksek frekanslarda ise kısa zaman aralıklı pencereleme yapılmasını sağlar. Başka bir tanımla kullanılan ölçeğin küçük olması durumunda işarete var olan yüksek frekanslı bileşenlerin, ölçek büyük olduğunda ise düşük frekanslı bileşenlerin analizi yapılması daha kolay bir hale gelir (Ramazan, 2009).

Genel tanım olarak dalgacık fonksiyonu olan $\psi_{\tau,s}(t)$ ile $x(t)$ giriş sinyalinin çarpılmasıyla dönüşüm yapılır. $\psi_{\tau,s}(t)$ dalgacıkları t sonsuza giderken merkez noktası ve dalgacığın ortalaması sıfırdadır (Yavuz, 2017). Ortalaması sıfır olan ve ön plana çıkaracağı

frekans bölgesi ayarlanabilen ana dalgacık fonksiyonu analizi yapılacak sinyale uygun olarak seçildikten sonra işaretin başlangıç noktasına konumlandırılır. Sinyalin seçili kısmına dalgacık dönüşümü yapılır. Kaydırma parametresi ile analizi yapılacak olan $x(t)$ sinyali üzerinde gezdirilerek her bir adımda dalgacık ile sinyal konvülasyon işlemine tabi tutularak dalgacık dönüşümü gerçekleştirilir (Yılmaz, 2020). Ana dalgacığın genişletilmesi ve sıkıştırılması ölçekleme parametresi ile, zaman ekseninde kaydırılması ise öteleme parametresi ile sağlanır.

Dalgacık dönüşümü sürekli dalgacık dönüşümü ve ayrık dalgacık dönüşümü olarak iki başlıkta sınıflandırılabilir. t zaman, τ öteleme parametresi, s ölçekleme parametresi, $x(t)$ sinyal, $\psi_{\tau,s}(t)$ dalgacık olarak belirlendiğinde Dalgacık fonksiyonu formül 1’de, konvülasyon işlemi ise formül 2’de ifade edilmiştir. Sürekli ve ayrık dalgacık dönüşümü ise tabloda formüsel olarak gösterilmiştir.

$$\psi_{\tau,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (11)$$

$$W(\tau, s) = \frac{1}{\sqrt{s}} \int x(t) \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (12)$$


Sürekli Zaman İşareti	
Sürekli Dalgacık Dönüşümü	Ayrık Dalgacık Dönüşümü
$W(\tau, s) = \frac{1}{\sqrt{s}} \int x(t) \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right)$	$W(\tau, s) = \frac{1}{\sqrt{s}} \int x(t) \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right)$
$s \in \mathbb{R}^+ - \{0\}, \quad \tau \in \mathbb{R}$	$s \in 2^j \quad \tau = k.2^j = k.s \quad j, k \in \mathbb{Z}^2$

Çalışmada uygulanan dönüşüm biçimi ayrık dalgacık dönüşümüdür. Sürekli dalgacık dönüşümündeki veri kapasitesinin büyük olması ve dalgacık katsayılarının ölçek değerinde hesaplandığı için çok miktarda katsayı oluşması işlemin verimliliğini düşürmektedir. Katsayıların yalnızca seçilen ölçekler ve zaman diliminde hesaplanabilmesi için ayrık dalgacık dönüşümünde konum ve ölçeklerin ikili kuvvetleri yalnızca alınması ayrık dalgacık

dönüşümü oluşturur. Ayırık dalgacık dönüşümünde bu şekilde daha az sayıda fakat yine de işaretin frekans ölçek bilgisi elde edilmiş olur. Elde edilen her bileşen iki ve ikinin katları olacak şekilde dalgacık katsayıları ve sinyal bilgisi kazanılmış olur (Ramazan, 2009; Partal, 2008).

Dalgacık analizinde en çok kullanılan ana dalgacıklar Morlet, Haar, Meksika şapka tipi, Daubechies dalgacıklarıdır. Çalışmada Daubechies dalgacık yöntemi ayırık dalgacık dönüşümü şeklinde 3 seviyede yapılmıştır.

Daubechies dalgacık dönüşümü ortalama ve farklar kullanılarak ölçekleme sinyalleri ile dalgacıklar üreten bir dalgacık analiz yöntemidir. Dengeli frekans yanıtlarına sahip olmasına rağmen doğrusal olmayan faz tepkilerine sahiptir. Örtüşen pencereler kullanması sayesinde yüksek frekans ölçümlerinde frekans değişiklikliklerini yansıtmada başarılıdır. Ses sinyallerinin sıkıştırılması, gürültü giderilmesinde kullanışlı yapıya sahiptir (Mahmoud, 2007). Şekil 18.'de çalışmada kullanılan daubechies-3 ana dalgacık ve ölçekleme fonksiyonu gösterilmiştir.



Şekil 18. Daubechies-3 ana dalgacık ve ölçekleme fonksiyonu.

Çalışmada 3 seviyeli db3 dalgacık dönüşümü kullanılarak “wpdec” fonksiyonu ile ayırık dalgacık dönüşümü gerçekleştirilmiştir. Belirli seviyedeki katsayıların enerjisi “wprcoef” fonksiyonu ile hesaplanarak her bir sütundaki belirli seviyedeki tüm enerjiler toplanmıştır. Toplam enerjilerin katsayı grup sayısına bölünmesi sonucu bulunan ortalama enerji ile öznelilik değerleri oluşturulmuştur.

2.3.10. Komşuluk Bileşen Analizi

K en yakın komşuluk algoritmasına dayalı boyu azaltma işlemi sırasında bilgilerin kaybolmaması işlemini sağlayan bir algoritma çeşididir. Amaç olarak sınıflandırma doğruluğunu maksimum yapacak niteliğe uygun özellik alt seçim kümesini belirler. Özellik vektörü x_i 'ye karşılık gelen ağırlık vektörünü bulmaya çalışır. Özellik seçimi gerçekleştirirken veri içindeki bilgilerde herhangi bir bilgi kaybı yaşanmaz. Mesafe ölçüm metrikleri dikkate alınarak elde edilen pozitif ağırlıklar özellik belirlenmesinde kritik unsurlardır. Yüksek ağırlık önem seviyesi yüksek olan özellikleri, daha düşük ağırlıklar ise daha az önemli olan özellikleri ifade eder (Tuncer,2019).

Bir x_i veri noktası verildiğinde x_i referans noktası alınarak çizilmek istenen x_j aşağıdaki gibi ifade edilir.

$$P_{ii}=0, P_{ij}=\frac{\exp(-||Ax_i-Ax_j||_2^2)}{\sum_{k \neq i} \exp(-||Ax_i-Ax_k||_2^2)} \quad (13)$$

Verilen i noktasının doğru sınıflandırma olasılığı aşağıdaki gibidir.

$$P_{ii}=\sum_{j \in C_1} P_{ij} \quad (14)$$

$C_i=(j|C_i=C_j)$ x_i ile aynı sınıftaki noktalar kümesini belirler.Sonuç olarak sınıflandırılma olasılığı aşağıdaki gibi hesaplanır (Qin, 2015).

$$P_{ii}=\sum_i \sum_{j \in C_1} P_{ij}=\sum_i P_i \quad (15)$$


2.3.11. Lineer Diskriminant Analizi

Lineer Diskriminant analizi ya da diğer adıyla doğrusal ayırma analizi boyut azaltma ve sınıflama için kullanılan çok değişkenli algoritmadır. 1936 yılında R. A. Fischer tarafından geliştirilmiş olan Fisher'in lineer diskriminant fonksiyonu veri setini doğru şekilde sınıflandırabilmek için gruplar arası kareler toplamının grup içi kareler toplamına oranını maksimize eden doğrusal bir fonksiyon olarak tanımlamıştır (Kaynak, 2019).

Makine öğrenmesi algoritmalarında birbirinden ayırt edilebilecek ve sınıflanacak nesnelerin kendine özgü desenlerini karakterize edebilmek için sınıf etiketleri atanır. Bunun yapılabilmesi için veri seti öncelikle eğitim veri kümesi olarak ayrıştırılarak eğitilir. Kalan

veri test veri kümesi olarak adlandırılır ve sınıfların doğru şekilde etiketlenip ayrıştırıldığını gözlemlemek için test yapılarak sistem performansı gözlemlenir. Fakat veri kümesinin özellik boyutu büyük olduğunda sınıflandırıcı performansını ve karmaşıklığı azaltabilmek için boyut azaltma teknikleri kullanılır. Boyut azaltmak için özellik çıkarımı veya özellik seçme yöntemi temel olarak kullanılır. Özellik seçme yönteminde yararlı olabilecek birkaç özellik seçilerek diğer özellikler elenir. Özellik çıkarma yöntemlerinde ise doğrusal (veya doğrusal olmayan) kombinasyonlar yapılarak orijinal özellikten birkaç özellik oluşturularak boyut azaltma işlemi gerçekleştirilir. Boyut azaltmada en çok kullanılan ve temel olarak bilinen TBA ve DDA yöntemleri bulunur. TBA gözetimsiz (sınıf etiketi olmadan) öğrenme algoritmasıdır ve kümeleme problemlerinde kullanılır. DDA ise gözetimli (sınıf etiketi bulunur) bir öğrenme algoritmasıdır ve sınıflama problemlerinde kullanılır (Sharma, 2015).

DDA tekniği farklı sınıflara ait yüksek boyutlu özellik vektörlerini düşük boyutlu özellik vektörüne indirgerken temel olarak fonksiyonu yönelim, sınıf içi dağılım matrisi ve sınıflar arası dağılım matrisi olarak üç faktörü dikkate alır. Şekilde görüldüğü gibi C1, C2 VE C3 olarak belirlenen 2 boyutlu 3 özellik vektörünün maksimum düzeyde birbirinden ayrılabilmesi için tek boyutlu W ve W^* özellik uzayına indirgenmiştir. W özellik uzayının W^* özellik uzayından sınıfları birbirinden ayırmada daha başarılı olduğu gözlenmektedir (Sharma, 2015). Şekil 19.'de Lineer Diskriminant Analizi görseli verilmiştir.



Şekil 19. Lineer Diskriminant Analizi.

C adet sınıfla çok sınıflı bir model sınıflandırma için $X = \{x_1, x_2, \dots, x_n\}$ n adet öznitelik vektörüne ve d boyutuna sahip olsun. X veri seti içinden $X_1, X_2, \dots, X_c$ adet sınıf içinde, n_j adet örnekleme sayısı içeren j sınıfına ait X_j eğitim alt kümesi oluşturursak;

$$n = \sum_{j=1}^c n_j \quad (16)$$

$$X_j \subset X, X_1 \cup X_2 \cup \dots \cup X_c = X \quad (17)$$

μ_j ; X_j 'nin merkezi (ortalaması), μ ; X'in merkezi(ortalaması) kabul edelim. Bu durumda toplam dağılım matrisi $S_T \in R^{d \times d}$, sınıf içi dağılım matrisi $S_W \in R^{d \times d}$, sınıflar arası dağılım matrisi ise $S_B \in R^{d \times d}$

Olarak ifade edilirse

$$\begin{aligned} S_T &= \sum_{x \in X} (x - \mu)(x - \mu)^T \\ S_W &= \sum_{j=1}^c \sum_{x \in X_j} (x - \mu_j)(x - \mu_j)^T \\ S_B &= \sum_{j=1}^c n_j (\mu_j - \mu)(\mu_j - \mu)^T \\ S_T &= S_B + S_W \end{aligned} \quad (18)$$

W'nin bir fonksiyonu olarak Fisher kriteri şu şekilde tanımlanabilir.

$$J(w) = |W^T S_B W| / |W^T S_W W| \quad (19)$$

|...| determinantı temsil eder. Yönlendirme matrisi W özdeğer problemi çözümü olarak nitelendirir.

$S_W^{-1} \cdot S_B \cdot w_i = \lambda_i \cdot w_i$ ifadesinde ise Özdeğerler(λ_i) büyükten küçüğe doğru sıralandığında özdeğerlere karşılık gelen özvektörlerden en iyi sonuçları verecek olan ilk $w_i = (i = 1 \dots h)$ tanesi ile oluşturulan W izdüşüm matrisi oluşturulur.

Çalışmada kullanılan veri seti DDA1, DDA2 ve DDA3 olmak üzere 3 adet sütun olarak boyutu indirgenmiştir.

2.4. Sınıflama Algoritmaları

2.4.1. k-En Yakın Komşuluk Algoritması

k-En Yakın Komşuluk Sınıflama (k-EYK) basit kullanım şekli ve performans olarak başarılı sonuçlar vermesi sebebiyle makine öğrenmesi algoritmasında sıklıkla kullanılan bir

sınıflama çeşididir. En iyi 10 veri madenciliği algoritmasından biri olarak kabul edilen sınıflama yöntemi başarılı sonuçlar vermektedir.

Sınıflandırmada temel amaç veri setinde eğitim veri kümesi olarak ayrılan kısımda gerekli noktaların belirlenerek test veri kümesindeki noktaların doğru etiketlerle atanabilmesidir.

Bu yöntemde sınıflandırma, öznitelik uzayındaki verilerin birbirine olan uzaklıklarına göre yapılmaktadır. k-En Yakın Komşuluk Sınıflama algoritması uzaklık ve k en yakın komşuluk değerleri temel alınarak tahmin yapmaktadır. Sınıflandırılması gereken test denemesinin, eğitim öznitelik uzayındaki denemelere olan uzaklıkları öncelikle hesaplanır.

Uzaklık ölçülerinde genelde Öklid mesafesi, Mahalanobis mesafesi ve Minkowsky mesafesi ve bunların varyantları gibi ölçümler ele alınır. Bu uzaklıklardan en küçük k tanesi dikkate alınarak oylama yöntemi ile test denemesinin ait olduğu sınıf belirlenir. k-EYK sınıflandırıcısında hem k parametresinin değeri hem de denemeler arasındaki uzaklıkların hesaplan yöntemi sınıflandırma sonucuna etki eden faktörlerdir (Zhang, 2017).

K en yakın komşuluk yönteminin uygulaması ve anlaşılması kolay olmasının yanı sıra en yakın komşu ortalaması dikkate alınarak sınıflama yapıldığı için gürültülü veriden fazlaca etkilenmemesi avantajı sayılabilir. En yakın komşu parametresi olan k değerinden ve seçilen uzaklık mesafesi yönteminden fazlaca etkilenmesi, verimli olabilmesi için büyük eğitim verisine ihtiyaç duyması sayılabilir.

Farklı veri tiplerine göre farklı uzaklık ölçütleri kullanılır. Bunlardan başlıcaları;

Minkowski uzaklığı:

$$d_{i,j} = [|x_{i1} - x_{j1}|^m + |x_{i2} - x_{j2}|^m + \dots + |x_{ip} - x_{jp}|^m]^{1/m} \quad (20)$$

Minkowski uzaklığında m=2 için öklid mesafesi hesaplanır. Öklid mesafesi k en yakın komşuluk sınıflaması mesafelerinde kullanılan bir mesafe yöntemidir.


$$d_{i,j} = \sqrt{|x_{i1} - x_{j1}|^2 + |x_{i2} - x_{j2}|^2 \dots + |x_{ip} - x_{jp}|^2} \quad (21)$$

Minkowski uzaklığında m =1 için Manhattan (City Blok) uzaklığı hesaplanır.

$$d_{i,j} = |x_{i1} - x_{j1}|^m + |x_{i2} - x_{j2}|^m + \dots + |x_{ip} - x_{jp}|^m \quad (22)$$

Maximum değer uzaklığı olarak da adlandırılabilen Chebysev uzaklığı ;

$$d_{i,j} = \max_m |x_{1m} - x_{2m}| \quad (20)$$



Şekil 20. K-En Yakın Komşuluk Algoritması.

Şekil 20.'deki örnekte yuvarlak kırmızı öznitelikler ω_1 sınıfına ait, mor üçgen öznitelikler ω_2 sınıfına ait, yeşil kare öznitelikler ise ω_3 sınıfına ait olsun. Yeni bir test örneği X_u geldiğinde ve k parametresi 5 seçildiğinde X_u 'nun önce en yakın mesafedeki 5 adet komşu özniteliği incelenir. Şekilde görüldüğü gibi 5 adet komşu öznitelikten kendisine en yakın 4 özniteliğin ω_1 sınıfına ait olduğu belirlenmiştir. O halde k en yakın komşu algoritmasına göre test örneği X_u ω_1 sınıfına atılır denilir (Köktürk, 2012).

Çalışmada en yüksek sınıflama doğrulukları k en yakın komşuluk yöntemiyle ve öklid mesafesi kullanılarak elde edilmiştir.

2.4.2. Destek Vektör Makineleri

DVM (Destek Vektör makineleri) çalışmaları 1960'lı yılların sonlarında başlayıp, 1990'lı yılların sonlarına doğru son halini alan; ünlü Rus matematikçi Vladimir Vapnik tarafından ortaya atılarak 1995 yılında kendisi tarafından bir sınıflandırma problemini ilk kez çözmede kullanılan bir makine öğrenme algoritmasıdır. Sınıflandırma problemleri yanı sıra regresyon problemlerinin çözümünde de kullanılan bir yöntemdir (Kaya, 2017).

Pazarlama, metin tanıma, görüntü ve veri sınıflama gibi birçok alanda yaygın olarak kullanılmasının sebepleri; diğer yöntemlere göre kullanımında hesaplama açısından kolaylık sağlaması, sinir ağları ve radyal tabanlı yapay sinir ağlarına benzerlik gösterse de genellikle

bu algoritmalarından daha iyi performans göstermesi, ölçeklenebilir oluşu sayılabilir. Veri setinin çok büyük ya da küçük oluşundan etkilenmeyerek ayrıca aykırı değerlerde sapma oranının düşük olması sebebiyle sınıflandırma ve regresyon problemlerinde performans açısından üstün niteliklidir (Zigic ve Kecman, 2014).

Sınıf etiketlerinin önceden bilinen bazı eğitim seti verilerinde destek vektör makineleri denetimli öğrenme sınıflandırma problemleri çözümleri yapar. Matematiksel olarak hedefi ayırım yapılacak sınıflar arasında optimal bir ayırma yüzeyi oluşturarak sınıflara eşit uzaklıkta olan hiperdüzlem arar. Doğrusal ve doğrusal olmayan sistemlerde kullanılmak üzere 2 ana başlığa ayrılabilir. Doğrusal olarak ayrılabilir durumda parametreler belirlenerek ana hatlar çizilir. Doğrusal olmayan karar yüzeyleri için kernel fonksiyonları dönüştürülerek kullanılır. Gürültülü verilerde ise doğru sınıflayabilmek için eğitim hatalarına izin verecek değişkenler tanıtılır.

DVM sınıflama hatasını minimuma indirirken geometrik marjı maksimum yapması sebebiyle maksimum marj sınıflandırıcı olarak da adlandırılabilir. Sınıfları yüksek performansla ayırt edebilmek için giriş vektörlerini daha yüksek boyuta taşıyıp, maksimum ayrılmayı sağlayan ayırıcı hiperdüzlem oluşturur. Bunun için ayırıcı hiperdüzlemin iki tarafında verileri ayıran paralel iki hiperdüzlem alanı geliştirir. Bu paralel hiperdüzlemler arasındaki marj veya mesafe ne kadar büyük olursa, sınıflandırma başarı performansı o kadar yüksek olur.

N adet örnekleme sayısına sahip birbirinden bağımsız Sınıf-1 ve Sınıf-2 ye ait eğitim verisi X_i ($i=1, 2, 3, \dots, N$) olduğunda ve sınıf etiketleri de Sınıf-1 için $Y_i=1$, Sınıf-2 içinse $Y_i=-1$ şeklinde ifade edildiğinde;

$$(X_1, Y_1), (X_2, Y_2), \dots, (X_N, Y_N) \quad X_i \in R^d ; Y_i \in (-1, +1)$$

Ayırıcı hiperdüzlemi elde etmek için;

$$WX+B=0$$

Burada b skaler bir değerdir ve p boyutunda n adet özneliğe sahip bir eğitim verisinde W ; p boyutlu bir vektördür. b nin eklenmesi sayesinde marj artar. b değeri olmadığı durumda hiperdüzlem orjinden geçeceği için çözüm noktasında başarısız olunmasına sebebiyet verir.

Paralel hiperdüzlemler ise aşağıdaki denklemlerle tanımlanır.

$$WX+B=1$$

$$WX+B=-1$$

Eğitim verilerinin doğrusal olarak ayrılabilirdiği durumlarda paralel hiperdüzlemleri arada hiçbir veri noktası olmayacak şekilde ayarlanabilir ve sınıflar arası mesafeyi


maksimize edilebilir. Paralel hiperdüzlemler arasındaki mesafe $2/|w|$ bağıntısıyla hesaplanır. SVM 'deki ana amaç hiperdüzlemler arasındaki mesafeyi maksimize etmek olduğu için $|w|$ parametresi minimum değerde olmalıdır (Bhavsar, 2012).

Bu bağıntıların gerçekleşebilmesi için veri setindeki noktaların aşağıdaki koşulları sağlaması gerekir;

$$w \cdot x_i - b \geq 1 ;$$

$$w \cdot x_i - b \leq -1$$

$$Y_i (w \cdot x_i) - b \geq 1 , 1 \leq i \leq N;$$



Şekil 21. Örnek Destek Vektör Makinesi Uygulaması

Şekil 21.' de örnek destek vektör makinesi uygulaması gösterilmiştir. Çalışmada k-En Yakın Komşuluk Sınıflama en yüksek performansı gösterse de DVM yöntemi kullanılarak da doğruluk performansı karşılaştırılmıştır.


2.4.3. Karar Ağacı

Karar Ağacı (KA) sınıflandırma algoritmalarında sıklıkla tercih edilen bir modelleme biçimidir. Yapı ve biçim olarak bir ağaca benzer. Tek bir kök düğümden çıkarak diğer düğümlere dalları olan ve alt düğümlerle de ilişkilendirip sonuç veren bir metodudur. Herhangi bir alt düğümü olmayan uç düğümler yaprak olarak nitelendirilir. Dalların her biri evet ya da hayıra götürüp sınıflamayı sağlayan test etiketine sahiptir. Veri seti küçük parçalara bölünerek geliştirilir. Her düğüm için düğüme gelen dalları etiketleyen test dizisi bir bölme niteliği taşır. Örneğin hangi sınıfa ait olduğunu belirlemek için Her veri alt kümesi

farklı ve uygun bir alt düğüme atanır. Bu şekilde her veri noktası için testlerden yalnızca biri doğru olarak değerlendirilip, sınıflama gerçekleşir (Cañete-Sifuentes, 2021).

Hata oranı bulunurken yanlış sınıflandırılan noktaların toplam sayısı toplam veri noktası sayısına bölünür. Birden hata oranı çıkartıldığında doğruluk oranı bulunur.

Sınıf etiketi önceden verilmiş verilerin sınıflandırıldığı denetimli bir sınıflama algoritmasıdır. En iyi kazancı belirlemek adına birçok karar ağacı algoritması çeşidi geliştirilmiştir. Diğer sınıflama örneklerinde de gözlenebileceği gibi daha büyük ve karmaşık karar ağaçları performans açısından daha düşük sonuçlar üretir. C4.5 ve random forest en iyi sonuçlar verebilen karar ağacı algoritma çeşitleridir (Kotsiantis, 2013). Şekil 22.' de karar ağacı öğrenme algoritması örneği verilmiştir.



Şekil 22. Karar Ağacı Öğrenme Algoritması Örneği

Karar ağacı öğrenme algoritmasında dikkat edilmesi gereken üç adet fonksiyon vardır. c sınıf sayısı ,pi veri olmak üzere (Kotsiantis, 2013);

Entropi (S)

$$S = -\sum_{i=1}^c p_i \log_2 p_i \quad (23)$$

Kazanç;

$$\text{Kazanç}(S,A) = \text{Entropi}(S) - \sum_{v \in A} \frac{|S_v|}{|S|} \text{Entropi}(S_v) \quad (24)$$

Kazanç Oranı;

$$\text{Kazanç Oranı}(S,A) = \text{Kazanç}(S,A) / \text{Alt Küme}(S,A) \quad (25)$$

Alt Küme;

$$\text{Alt Küme}(S,A) = \sum_{i=1}^c \left(\frac{|S_i|}{|S|} \right) \log_2 \left(\frac{|S_i|}{|S|} \right) \quad (26)$$

Karar ağacı öğrenme algoritması kategorik ve sürekli veriler ile işlem yapılabilmesi yanısıra ayrık değerli sınıflandırıcıyı gösterimde de başarılı performans göstermesi, uygun yaprak sayısı ile birlikte anlaşılmasının kolay olması, hatalı veya eksik verilerde de uygulanabilmesi açısından avantajlara sahiptir. Fakat böl ve yönet prensibi ile çalıştığı için performansının düşük olması ya da bazı algoritmalarda kesikli değerlere ihtiyaç duyması ve ilişkili olmayan öznitelikleri de algılayabilmesi açısından dezavantajları bulunan bir algoritma çeşididir (Aslan, 2022).

Çalışmada k-En Yakın Komşuluk Sınıflama en yüksek performansı gösterse de karar ağacı yöntemi ile de doğruluk performansı karşılaştırılmıştır.

2.4.4. Naive Bayes Yöntemi

Naive bayes yöntemi makine öğrenmesi sınıflandırmalarında ve tıbbi teşhisler, otonom araç kontrolü, ürün önerileri gibi gerçek dünya uygulamalarına da sahip basit ve yüksek performans gösteren olasılıksal bir sınıflama algoritmasıdır.

Sınıflandırma algoritmaları temelde olasılıksal veya olasılıksal olmayan olarak sınıflandırılabilir. Örnek olarak destek vektör makineleri ve k en yakın komşu algoritması olasılıksal olmayan sınıflandırma yöntemleridir. Naive bayes ise dağılıma odaklı, lojistik regresyon ve çok katmanlı algılayıcıları içeren olasılıksal sınıflama yöntemidir (Wickramasinghe, 2021).

Naive bayes basit kullanımı yanında algoritma olarak da güçlü ve etkili performanslar gösterir.


Yeni gelen x nesnesinin her bir y sınıfına atanması için olasılığını tahmin edebilmek için $P(y|x)$ örnek verideki bilgiyi kullanarak sınıflama işlemini gerçekleştirir. Eğitim ve sınıflama süresi özniteliklerin sayısına göre doğrusal olarak belirlenir. Sınıflama süresi eğitim örnek sayısından etkilenmemektedir bu açıdan hesaplama olarak verimlidir. Düşük

varyans özelliğine sahiptir. Sınıflandırılacak örnekleri gürültüden çok fazla etkilenmeden sınıflama işleme yapar.

$X_1, X_2, \dots, X_n$; n boyutlu S_x olarak ifade edilen bir verinin vektörleri olsun. $x_1, x_2, \dots, x_n$ karşılık gelen örnekler olsun. Y ise S_y alanına ait daha hangi sınıfa ait olduğu bilinmeyen gözlenmemiş rastgele bir değişken olsun. S_x 'den S_y 'ye bağlantılı bir fonksiyon olduğu varsayılırsa amaç olarak $x_1, x_2, \dots, x_n$ e karşılık gelen y_i değerlerini tahmin etmeyi belirler. $P(Y=y|X=x)$ gösterimi şekilde aradaki bağlantıyı maksimum uyumlayacak Y sınıfını seçmek hedeflenir. $P(Y = y)$ ve $P(X = x|Y = y)$ öncü ve sınıf koşulluk olasılıkları temsil eder. $P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n|Y = y) = \prod_{i=1}^n P(X = x_i|Y = y)$ naive bayes yönteminin koşullu bağımsızlık durumunu ifade ediş biçimidir. K y'ye ait bir sınıf durumu olduğu kabul edilirse;

$$\begin{aligned}
 & P(Y = y|X = x) \\
 &= \frac{P(Y = y, X = x)}{P(X = x)} \\
 &= \frac{P(Y = y)P(X = x|Y = y)}{P(X = x)} \\
 &= \frac{P(Y = y)P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n|Y = y)}{\sum_i^K P(y_i, X = x)} \\
 &= \frac{P(Y = y) \prod_{i=1}^n P(X = x_i|Y = y)}{\sum_i^K P(y_i, X = x)}
 \end{aligned}$$

Şekil 23.' de 3 sınıfı birbirinden ayıran örnek bir naive bayes yöntemi gösterimi verilmiştir.



Şekil 23. Naive Bayes Yöntemi

3. BULGULAR

3.1. Sensör Eliminasyonu

1. ve 5.sensör ($C_2H_4O_2$ algılayıcı sensör) aslında gözlemlenen verilerin doğruluğunu ölçebilmek adına aynı seçilmiştir. İki sensörün algıladığı değer arasındaki fark eğer 1 mg/L ‘den büyükse sistem bu verileri anormal kabul edecek ve elimine edecektir.

Bu işlem için öncelikle iki sensör arasında oluşması istenen farkın kabul edilebilir bir eşik değeri 1 olarak kabul edilmiştir. Hata oran eşik değeri 0,1 alınmıştır.1.ve 5.sensör için 150-300 saniye örnekleme aralığındaki değerler için gözlenim yapılmıştır.

Nitelikleri sağlamayan değerler veri setinden elinerek hata payı azaltılmıştır. *Aspergillus niger* enjekte edilen elma örneklerinden elenen veri olmamıştır ve sonuç olarak 40 adet elma örneği kullanılmaya devam edilmiştir. Taze elmalardan alınan örneklerde 2.,3.,22.,26.,27,29.,30.,33., alınan 8 adet örnek elenerek 32 örnek kalmıştır. *Penicillium crustosum* enjekte edilen elma örneklerinden 10.39. ve 40. Örnek elenerek 37 adet örnek kalmıştır. *Penicillium expansum* enjekte edilen elma örneklerinden elenen veri olmamıştır ve sonuç olarak 40 adet elma örneği kullanılmaya devam edilmiştir. Elenen örnekler sonucunda veri seti toplam 160 örnekten 149 örneğe indirgenmiştir. Bu aşamadan sonra kalan verilerin hepsi eliminasyon adlı bir klasörde toplanır.

3.2. Öznitelik Çıkarma

Öznitelik çıkarma aşamasında öncelikle komşuluk bileşen analizi fonksiyonu kullanılarak önemli özniteliklerin çıkarılıp kullanılmasıyla sınıflama işlemi yapılmıştır. Komşuluk bileşen analizi metodunda sınıflama algoritmalarının en yüksek sonucu verebilmesi için en iyi sonuçları verebilecek parametrik olmayan özellikler seçilir ve sınıflamaya sokulur. Sınıflama modeli olarak k-En Yakın Komşuluk Sınıflama, desicion tree ve k-En Yakın Komşuluk Sınıflama sınıflama yöntemleri kullanıldığında 4 sınıf ayırımında çıkan en yüksek doğruluk oranları tabloda gösterilmiştir.

Tablo 6. Komşuluk Bileşen Analizi

Sınıflama Yöntemleri	Sonuçlar	
	Test Doğruluğu	Cevaplama Süresi
k-EYK	66.21	9.sn
Karar Ağacı	71.62	74.sn
DVM	64.86	45.sn

Tablo 6 incelendiğinde cevaplama süresi kısa olsa da çıkan doğruluk oranlarının çok yüksek olmadığı gözlemlenir.

3.3. Bant Genişliği Özniteliği ile Elde Edilen Sonuçlar

Sensör eliminasyonu işlemi sırasında 160 adet veri örneğinden elenen 149 adet veri öncelikle sadece her veri için örnekleme saniyesi 31.saniye ile 300.saniye arası 270 saniye olarak ortak bir örnekleme saniyesi seçilerek bant genişliği özniteliğine sokulmuştur. *Aspergillus niger* enjekte edilmiş sınıf AN sınıfı olarak, Taze elma sınıfı F olarak, *Penicillium Crustosum* mantarı enjekte edilmiş sınıf PC olarak, *Penicillium Expansum* mantarı enjekte edilmiş sınıf PE olarak belirlenmiştir ve sınıf etiketleri atanmıştır. 8 adet sensörün özniteliği taramasının ardından lineer diskriminant analizi işlemi ile boyutu 149*3 olarak azaltılmıştır. Sırası ile k en yakın komşuluk, destek vektör makinesi, karar ağacı ve bayes sınıflama yöntemleri ile 10 katlı doğrulama işlemi yapıldığında tablodaki sonuçlar gözlemlenmiştir.

Tablo 7 incelendiğinde en yüksek sonucun k en yakın komşuluk yöntemi ile %66.52 ortalama test doğruluğu ve %75.56 ortalama eğitim doğruluğu verdiği gözlemlenmiştir. Fakat doğruluk değerleri bant genişliği özniteliğinin tek başına sınıf ayırma performansında çok yüksek sonuç vermediğini gösterir.

Tablo 7. Bant Genişliği Sonuçları

Sonuçlar	Ortalama Test Doğruluğu	Ortalama Eğitim Doğruluğu
k-EYK	66.52	75.76
DVM	60.38	65.47
Karar Ağacı	62.33	73.75
Naive Bayes	60.48	61.45

3.4. Dalgacık Dönüşümü Özniteliği ile Elde Edilen Sonuçlar

Sensör eliminasyonu işlemi sırasında 160 adet veri örneğinden elenen 149 adet veri öncelikle sadece her veri için örnekleme saniyesi 31.saniye ile 300.saniye arası 270 saniye olarak ortak bir örnekleme saniyesi seçilerek daubechies dalgacık dönüşümü özniteliğine sokulmuştur. *Aspergillus niger* enjekte edilmiş sınıf AN sınıfı olarak, taze elma sınıfı F olarak, *Penicillium crustosum* mantarı enjekte edilmiş sınıf PC olarak, *Penicillium expansum* mantarı enjekte edilmiş sınıf PE olarak belirlenmiştir ve sınıf etiketleri atanmıştır. 8 adet sensörün özniteliği taramasının ardından lineer diskriminant analizi işlemi ile boyutu 149*3 olarak azaltılmıştır. Sırası ile K en yakın komşuluk, destek vektör makinesi, karar ağacı ve bayes sınıflama yöntemleri ile 10 katlı doğrulama işlemi yapıldığında Tablo 8.'deki sonuçlar gözlemlenmiştir.

Tablo 8. Dalgacık dönüşümü özniteliği sonuçları

Sonuçlar	Ortalama Test Doğruluğu	Ortalama Eğitim Doğruluğu
k-EYK	69.19	74.56
DVM	61.95	62.72
Karar Ağacı	61.05	73.30
Naive Bayes	60.42	60.77

Tablo 8'deki sonuçlar incelendiğinde en yüksek sonucun k en yakın komşuluk yöntemi ile %69.19 ortalama test doğruluğu ve %74.56 ortalama eğitim doğruluğu verdiği gözlemlenmiştir. Fakat doğruluk değerleri dalgacık dönüşümü özniteliğinin tek başına sınıf ayırma performansında çok yüksek sonuç vermediğini gösterir. Bu sebeple dalgacık dönüşümüne ek olarak istatistiksel öznitelik yöntemleri kullanılır.

3.5. İstatistiksel Öznitelikler Birlikte Kullanılması İle Elde Edilen Sonuçlar

Sensör eliminasyonu işlemi sırasında 160 adet veri örneğinden elenen veriler sonucu geriye kalan 149 adet verideki her sensörün örnekleme saniyesi boyunca (örnekleme saniyesi 31.saniye ile 300.saniye arası 270 saniye olarak ortak bir örnekleme saniyesi seçilmiştir.) ortalama, standart sapma, varyans, integral, gradyan değerlerin maksimumu, gradyan değerlerin ortalaması, diferansiyellerin toplamı, diferansiyellerin varyansı ve medyan değeri olmak üzere 9 adet istatistiksel öznitelik uygulanmıştır. 8 sensörün 9 adet özniteliği 149 veri

için taraması sonucu veri büyüklüğü 149*72 olmuştur. *Aspergillus niger* enjekte edilmiş sınıf AN sınıfı olarak, taze elma sınıfı F olarak, *Penicillium crustosum* mantarı enjekte edilmiş sınıf PC olarak, *Penicillium expansum* mantarı enjekte edilmiş sınıf PE olarak belirlenmiştir ve sınıf etiketleri atanmıştır. Ardından lineer diskriminant analizi işlemi ile boyutu 149*3 olarak azaltılmıştır. Sırası ile k en yakın komşuluk, destek vektör makinesi, karar ağacı ve bayes sınıflama yöntemleri ile 10 katlı doğrulama işlemi yapıldığında tablo 9’ da gözlemlenmiştir.

Tablo 9. İstatistiksel özniteliklerin birlikte kullanım doğruluk sonuçları

Sonuçlar	Ortalama Test Doğruluğu	Ortalama Eğitim Doğruluğu
k-EYK	97.33	98.28
DVM	91.24	93.59
Karar Ağacı	90.57	95.23
Naive Bayes	97.24	98.88


Tablo 9’deki sonuçlar incelendiğinde k en yakın komşuluk yöntemi ile %97.33 ortalama test doğruluğu ve %98.28 ortalama eğitim doğruluğu verdiği gözlemlenmiştir. Naive Bayes sınıflamada ise %97.24 ortalama test doğruluğu, %98.88 ortalama eğitim doğruluğu gözlenmiştir. İstatistiksel özniteliklerin birlikte kullanılması ve veri boyutunu lineer diskriminant analizine girmeden önce yüksek tutulmasının sınıflama başarısını artırdığı gözlemlenmektedir.

3.6. İstatistiksel Özniteliklerin Dalgacık Dönüşümü ile Birlikte Kullanımı

Eliminasyon klasöründe toplanan elimine edilmiş verilerin hepsi liste uzunluğunca bir döngüye alınarak taranır. Verinin 31.örnekleme saniyesinden 300.örnekleme saniyesi aralığı ele alınır. Bu aralıktaki verilere sırasıyla integral, maksimum gradiyent, ortalama gradiyent, varyans, dalgacık dönüşümü, ortalama, standart sapma, diferansiyellerin toplamı, diferansiyellerin varyansı, medyan olarak toplam 10 adet öznitelik 8 sensör için uygulanır. Bu özniteliklerin hepsi öznitelik dosyasında saklanır. Sonrasında etiketlerin oluşması için *Aspergillus niger* 0, fresh 1, *penicillium crustosum* 2, *Penicillium expansum* 3 etiketine sahip olarak oluşturularak etiketler ve öznitelik işlemi uygulanan veriler birleştirilip mat ve csv dosyası olarak kaydedilir.

Oluşan dosyamızın boyutu 149*81 e sahiptir. 149 toplam veri sayısını temsil eder. 81 ise 8 sensörün 10 adet öz niteliği taramasını ve etiketleri ifade eder.

AN, PE, PC VE F elimine edilmiş ve öz niteliği çıkarılmış verilerin 3 boyutlu ortamda gösterimi aşağıdaki gibidir.




Şekil 24. DDA işlemi öncesi

Öznitelikler çıkarıldıktan sonra sınıflamaya sokulduğunda yüksek sınıflama sonuçları elde edilmemesinden ötürü veriler Doğrusal Diskriminant Analizi işlemine tutulurlar.

3.7. Doğrusal Diskriminant Analizi İşlemi

Eliminasyon işlemi yapılan ve öz nitelikleri çıkarılan veriler okunduktan sonra z -score normalizasyonu işlemine uğrarlar. Sınıf ortalamaları alındıktan sonra sınıf içi ve sınıf dışı dağılım değerleri hesaplanır. Elde edilen değerlere göre özvektörler ve özdeğerler hesaplanarak 149*81 boyutlu veri sınıf etiketlerinden ayrıştırılarak 149*3 boyutuna indirgenerek Doğrusal Diskriminant Analizi boyut azaltım işlemi gerçekleştirilmiş olur. Boyutu azaltılmış verinin ve sınıfların 3 boyutlu görüntüsü ve tek düzlemde 4 sınıfın görüntüsü şekilde verilmiştir.



Şekil 25. DDA işlemi ile boyutu azaltılmış verilerin 3 boyutlu görüntüsü

3.8. Sınıflama İşlemi

Bu aşamada öncelikle veriler okunur ardından etiket değerleri ve veri değerleri ayrıştırılır. Random şekilde etiketler ve veriler karıştırılır. Toplam 149×3 boyutlu veri 134×3 olacak şekilde eğitim verisine, 134×1 eğitim etiketleri olarak ayrıştırılır. Kalan 15×3 test verisi, 15×1 test etiketidir. Eğitim veri seti k adet parçaya (çalışmada 10 seçilmiştir) bölünerek bölünen parçaları kendi içinde doğrulamak için 10 katlı k katlamalı çapraz doğrulamaya sokulur. Bu işlem sistemin doğruluğunu, performansını artırmak için yapılır. Sonrasında sınıflama yöntemleri ile doğruluk oranları tespit edilmiştir.


3.8.1. k-En Yakın Komşuluk Sınıflama Sonuçları

Sistemde k-En Yakın Komşuluk Sınıflama sınıflama için Öklid mesafesi dikkate alınarak sınıflama gerçekleştirilmiştir. En yakın komşu parametresi 5 olarak seçildiğinde en iyi

sonuçların alındığı gözlemlenmiştir. 10 katlı çapraz doğrulamanın ortalaması alınarak ortalama sınıf doğruluk oranı belirlenmiştir.


3.8.1.1. Test ve Eğitim Doğruluğu

K-En Yakın Komşuluk test doğrulukları Şekil 26’de verilmiştir.



Şekil 26. K-En Yakın Komşuluk Test Doğruluğu

k-En Yakın Komşuluk Sınıflamada 10 adet sonucun ortalaması olarak test doğruluğu %99.33 standart sapması ise 2.10 olarak bulunmuştur. K-En Yakın Komşuluk Eğitim Doğruluğu Şekil 27’de verilmiştir.




Şekil 27. K-En Yakın Komşuluk Eğitim Doğruluğu

k-En Yakın Komşuluk Sınıflamada 10 adet sonucun ortalaması olarak eğitim doğruluğu %99.25 Standart sapması ise 0.35 olarak bulunmuştur.

3.8.2. Destek Vektör Makineleri Sınıflama

Destek Vektör Makineleri sınıflamada k-En Yakın Komşuluk Sınıflamadan farklı 10 kat çapraz doğrulama kullanılmıştır. Veri seti Toplam 149×3 boyutlu veri 134×3 olacak şekilde eğitim verisine, 134×1 eğitim etiketleri olarak ayrıştırılır. Kalan 15×3 test verisi, 15×1 test etiketidir.


Destek vektör makinesi test doğruluğu Şekil 28’de verilmiştir.



Şekil 28. Destek Vektör Makinesi Test Doğruluğu

Destek Vektör Makineleri sınıflamada 10 adet sonucun ortalaması olarak test doğruluğu %97.33 Standart sapması ise 3.44 olarak bulunmuştur.

Destek Vektör Makinesi Eğitim Doğruluğu Şekil 29’da verilmiştir.




Şekil 29. Destek Vektör Makinesi Eğitim Doğruluğu

Destek Vektör Makineleri sınıflamada 10 adet sonucun ortalaması olarak eğitim doğruluğu %96.50 Standart sapması ise 1.72 olarak bulunmuştur.


3.8.3. Karar Ağacı

Karar Ağacı sınıflamada da 10 katlı çapraz doğrulama kullanılmıştır. Karar Ağacı Test Doğruluğu Şekil 30’da verilmiştir.



Şekil 30. Karar Ağacı Test Doğruluğu

Karar Ağacı sınıflamada 10 adet sonucun ortalaması olarak test doğruluğu %91.24 Standart sapması ise 5.59 olarak bulunmuştur. Karar Ağacı Eğitim Doğruluğu Şekil 31’de verilmiştir.




Şekil 31. Karar Ağacı Eğitim Doğruluğu

Karar Ağacı sınıflamada 10 adet sonucun ortalaması olarak eğitim doğruluğu %96.12 Standart sapması ise 0.46 olarak bulunmuştur.


3.8.4. Naive Bayes Sınıflama

Naive Bayes sınıflamada 10 katlı çapraz doğrulama kullanılmıştır. Naive Bayes Test Doğruluğu Şekil 32’de verilmiştir.



Şekil 32. Naive Bayes Test Doğruluğu

Naive bayes sınıflamada 10 adet sonucun ortalaması olarak test doğruluğu %98.61 Standart sapması ise 2.91 olarak bulunmuştur. Naive Bayes Eğitim Doğruluğu Şekil 33’de verilmiştir.



Şekil 33. Naive Bayes Eğitim Doğruluğu

Naive bayes sınıflamada 10 adet sonucun ortalaması olarak eğitim doğruluğu %99.32 olarak bulunmuştur. Standart sapması ise 0.25 bulunmuştur.

Tüm sınıflamalardaki ortalama değerler tablo 10’da verilmiştir.

Tablo 10. Test ve Eğitim Doğruluklarında Ortalama En Yüksek Sonuçlar

Sınıflama Türleri	Test Doğruluğu	Test Standart Sapması	Eğitim Doğruluğu	Eğitim Standart Sapması
k-EYK	%99.33	2.10	%99.25	0.35
DVM	%97.33	3.44	%96.50	1.72
DESİCİON TREE	%91.24	5.59	%96.12	0.46
NAİVE BAYES	%98.61	2.91	%99.32	0.24

Elde edilen sonuçlardaki ortalama sınıflama doğrulukları tabloda belirtilmiştir. Fresh elmaların mantar enfekte edilmiş elma ile ayrımında; 4 sınıfın birbirinden ayrılmasında en yüksek sınıflama test doğruluğunun k-En Yakın Komşuluk Sınıflama yöntemi %99.33’e ulaştığı gözlemlenmiştir. Test doğruluğunda 2.en yüksek doğruluk değeri naive bayes yöntemi ile %98.61 bulunmuştur.

Taze elmaların mantar enfekte edilmiş elma ile ayrımında; 4 sınıfın birbirinden ayrılmasında eğitim doğruluk oranlarına bakıldığında ise en yüksek sınıflama eğitim doğruluğunun Naive bayes yöntemi %99.32’a ulaştığı gözlemlenmiştir. Eğitim doğruluğunda 2.en yüksek doğruluk değeri k en yakın komşuluk yöntemi ile %99.25 bulunmuştur.

En yüksek test doğruluğu veren algoritma k en yakın komşuluk yöntemi ile sağlanmıştır. K e yakın komşuluk sınıflamasında test ve eğitim doğrulukları farklı oranlarda belirlendiğinde Tablo 11’de gözlemlenmiştir.

Tablo 11. k-En Yakın Komşuluk Sınıflama farklı oran sonuçları

Oranlar	Ortalama Test Doğruluğu	Std Sapma	Ortalama Eğitim Doğruluğu	Std Sapma
0.15	97.72	2.39	99.21	0.37
0.20	96.00	4.09	98.90	0.69
0.40	95.50	2.61	98.31	0.95

Yapılan çalışmada veri setinde en yüksek test ve doğruluk oranı k en yakın komşuluk yöntemi ile bulunmuştur. Veri seti %10 test %90 eğitim olarak ayrılmıştır. Veri setindeki ayırma oranını değiştirdiğimizde k en yakın komşuluk yönteminde Veri seti %15 test %85 eğitim olarak ayrıldığında, %20 test ve %80 eğitim olarak ayrıldığında ve %40 test %60 eğitim olarak ayrıldığında k en yakın komşuluk sınıflama yönteminde elde edilen sonuçlar tablodaki gibidir. Sonuçlar genel olarak incelendiğinde oran arttıkça başarı oranının düştüğü görülür.

Genellikle boyutu çok da yüksek olmayan veri setlerinde %10 test, %90 eğitim olarak veri setinin ayrıştırılmasının modelin başarı performansında yüksek sonuçlar verdiği gözlemlenir.

4. TARTIŞMA

Bu çalışmada, *Penicillium expansum*, *Aspergillus niger* ve *Penicillium crustozum* ile aşılانmış taze ve küflü elmaları tespit etmek ve sınıflamak için elektronik burun sistemi kullanılmıştır. Elektronik burun ile elde edilen verilere çeşitli öznitelik yöntemleri uygulanmıştır. Sınıflama için k-En Yakın Komşuluk Sınıflama (k-EYK), bayes, karar ağacı ve destek vektör makinesi (DVM) dört örüntü tanıma yöntemi kullanılmıştır.

Literatürde yapılan çalışmaların genelde meyvelerin çürük olup olmadığının tespit edilmesine odaklanıldığı, az sayıda çalışmanın elmalarındaki mantar çeşitlerinin sınıflamasına dikkat çekildiği gözlemlenmektedir. Bu çalışmada Zhao vd. (2022) tarafından yayınlanan “Electronic Nose Characteristics of Apples Infected with Different Fungi” adlı veri seti kullanılmıştır. Veri seti sınıflamasında öncelikli olarak ham veriye anormal değerleri eleyebilmek için sensör eliminasyonu işlemi uygulanmıştır. Sensör eliminasyonu işlemi ardından verilere öznitelik çıkarma işlemi uygulanmıştır. Öznitelik çıkarma işlemi sonucunda sınıflama işlemine sokulduğunda en iyi sonuçlar çıkan öznitelikler birlikte kullanılarak doğruluk oranlarını yükseltebilmek için Doğrusal Diskriminant Analizi işlemi uygulanarak verilerin boyutu azaltılmıştır. Veri boyutları azaltılarak k-En Yakın Komşuluk Sınıflama, destek vektör makinesi, karar ağacı ve naive bayes yöntemleriyle sınıflama işlemleri uygulandığında en yüksek test doğruluğunun k-En Yakın Komşuluk Sınıflamada elde edildiği gözlenmiştir.

Jia vd. (2019) yılında yaptığı çalışmada *Penicillium expansum* ve *Aspergillus niger* ile aşılانmış taze ve küflü elmaları tespit etmeyi amaçlarken en yüksek sınıflama doğruluğuna Geri yayılım-yapay sinir ağları yöntemi ile ulaşmıştır. Guo vd. (2020) ise yaptığı çalışmada elmalara *Penicillium expansum* mantarını farklı seviyelerde enjekte etmiştir. Taze elma ile farklı seviyede enjekte edilen *Penicillium expansum* mantarını sınıflamada en yüksek doğruluk oranına temel bileşen analizi-ayırıcı analiz ile ulaşmıştır. Guo vd. (2021) yaptığı çalışmada ise *Aspergillus niger*, *Penicillium expansum*, *Penicillium chrysogenum* ve *Alternaria alternata* dahil olmak üzere dört baskın bozulma mantarını elma örneklerine aşılانmıştır. Taze elma ile farklı seviyede enjekte edilen mantar örneklerinde en yüksek başarı oranına Geri yayılım-yapay sinir ağları ile ulaşmıştır.

Bu çalışmada elde edilen test ve eğitim doğruluk oranının Zhao vd. (2022) yaptığı çalışmadan daha yüksek olduğu gözlemlenmiştir. Zhao vd. (2022) yaptığı çalışmada ham

veri sensör eliminasyonu işlemine sokulduktan sonra verilere 6 adet öznitelik çıkarma işlemi uygulanmışlardır. Öznitelik çıkarma işleminden sonra verilerin elimine edilmesi için maholonbis mesafesi uygulanarak veri boyutu azaltılmıştır. Sonrasında çeşitli sınıflama yöntemlerine sokulmuştur.

Zhao vd. (2022) yaptığı çalışmada veri boyutu doğrusal diskriminant analizi işleminden önce ham veri üstünde sensör eliminasyonu, maholonbis mesafesi eliminasyonuna tabi tutulmuştur. 6 adet öznitelik kullanmışlardır. Doğrusal Diskriminant Analizi kullanılarak boyut azaltılma işleminden sonra veri seti 130×3 haline getirilmiştir. Yapmış olduğumuz çalışmada ise sadece sensör eliminasyonu yapılarak ve 10 adet öznitelik kullanılarak veri boyutu 149×80 olarak belirlenmiştir. Doğrusal Diskriminant Analizi işlemine sokulduğundaki veri boyutu 149×3 'e düşmüş ve sınıflandırmaya o şekilde girmiştir.

Yapılan bu çalışmada daha yüksek sınıflama oranının bulunması sebebi olarak kullanılan öznitelik sayısının artırılarak veri boyutunun artırılması ve ham veri üzerinde eleme işleminin daha az şekilde yapılması söylenebilir. Eliminasyon işleminin daha az yapılması ve öznitelik seçiminde daha fazla ve uygun öznitelikler kullanılması çalışmanın doğruluk oranının artmasına etken olduğu düşünülmektedir.

Zhao vd. (2022) yaptığı çalışmada sınıflama yöntemi olarak en yüksek doğruluk oranı Serçe Arama Algoritması ve Geri Beslemeli Yapay Sinir Ağı yöntemiyle bulunmuş ve eğitim doğruluğu gözlenmiştir. Yaptığımız çalışmada ise test sınıflamasında hem k-En Yakın Komşuluk Sınıflamada hem de naive bayes sınıflamasında doğruluk oranı söz konusu olan çalışmadan daha yüksek gözlemlenmiştir. Eğitim doğruluğu olarak da k-En Yakın Komşuluk Sınıflama, naive bayes sınıflama doğruluk oranı olarak Zhao vd. (2022) yaptığı çalışmadan daha yüksek olduğu incelenir.

5. SONUÇLAR VE ÖNERİLER

Yüksek lisans çalışması olarak hazırlanan bu tezde, elde edilen sonuçlar incelendiğinde; elektronik burun kullanarak taze küflü elmaları etkili bir şekilde sınıflanabildiği gözlenmiştir. Bunun yanında söz konusu yöntemle farklı mantar çeşitleri arasında ayırım yapılabilebileceği de görülmüştür. Çalışmada, Zhao vd. (2022) tarafından yayınlanan “Electronic Nose Characteristics of Apples Infected with Different Fungi” adlı veri seti kullanılmıştır. Söz konusu veri seti 160 adet olgun elma örneğini içermekte olup, taze elmalar ve *Aspergillus niger*, *Penicillium expansum* ve *Penicillium crutosum* mantarları ile enfekte olmuş elmalar 4 farklı grupta toplanmıştır. Veri boyutları azaltılarak farklı yöntemlerle sınıflama işlemleri uygulandığında en yüksek test doğruluğunun %99.33 ile k-en yakın komşuluk sınıflamasında ve 2.en yüksek test doğruluğunun %98.61 ile naive bayes sınıflamada elde edildiği gözlenmiştir. Eğitim doğruluğunda ise en yüksek eğitim sınıflama doğruluğu naive bayes sınıflama ile %99.32, 2.en yüksek eğitim doğruluğu ise k -en yakın komşuluk sınıflamasında %99.25 elde edilmiştir. Çalışma sonuçları eğitim doğruluğunda naive bayes sınıflama yönteminin daha başarılı olduğunu gösterse de k-en yakın komşuluk sınıflaması test doğruluğu bakımından önde olduğunu ve daha güvenilir bir sonuç verdiğini göstermiştir. Bu bakımdan önerilen yöntem olarak k-en yakın komşuluk sınıflaması gösterilebilir.

Örnekleme sayısında eliminasyon işleminin gerekli ölçülerde yapılması sistemdeki başarıyı artırmıştır. Veri setinde uygun özneliliklerin birlikte kullanılmasının ve boyut azaltma işleminden önce boyutun büyük tutulmasının etkili olduğu belirlenmiştir. Doğrusal diskriminant analizinin veriye uygun olup boyut indirgemenin sistem performansını artırdığı gözlemlenmiştir.

Bu çalışmadaki sonuçlar, elektronik burnunun taze ve küflü elmaları etkili bir şekilde sınıflayabildiğini ve farklı mantar çeşitleri arasında ayırım yapabildiğini kanıtlamaktadır. Yürütülen bu çalışma ile elmadaki küfün tespitinde elektronik burun ile düşük maliyetli, düşük karmaşıklıkta ve hızlı bir sonuç sunduğu düşünülmektedir. Elektronik burun sistemleri ile meyve sebze sektöründe olduğu gibi, gıda teknolojisi gibi çeşitli alanlarda da güvenilirlik ve kalite çalışmalar yürütülebileceği öngörülmektedir.

6. KAYNAKLAR

- Arshak, K., Moore, E., Lyons, G. M., Harris, J., & Clifford, S. (2004). A Review Of Gas Sensors Employed in Electronic Nose Applications. *Sensor review*, 24(2), 181-198.
- Aslan, İ. (2022). *Veri Madenciliğinde Karar Ağacı Algoritmaları: Ufuk Üniversitesi Öğrenci Verileri ile Bir Çalışma*. Ufuk Üniversitesi Sosyal Bilimler Enstitüsü, Ankara.
- Aydemir, Ö. (2016). *Classification of electroencephalography signals recorded during smelling of valerian and rosewater odors*. In 2016 39th International Conference on Telecommunications and Signal Processing (TSP), 392-395.
- Aydemir, Ö. (2016). Common Spatial Pattern-Based Feature Extraction From The Best Time Segment of BCI Data. *Turkish Journal of electrical engineering and computer sciences*, 24(5), 3976-3986.
- Bawang, Z. (2014). Gas sensors: A review. *Sens. Transducers*, 168(4), 61-75.
- Beyhan, S., & Çetin, M. (2019). Elektronik Burun Tasarımı ve Literatür Araştırması. *Otomatik Kontrol Türk Milli Komitesi 2019 Ulusal Toplantısı*, Muğla Sıtkı Koçman Üniversitesi, 11-14 Eylül 2019, Muğla.
- Bhargava, A., & Bansal, A. (2020). Quality Evaluation of Mono & Bi-Colored Apples With Computer Vision And Multispectral Imaging. *Multimedia Tools and Applications*, 79, 7857-7874.
- Buck, L., & Axel, R. (1991). A novel multigene family may encode odorant receptors: a molecular basis for odor recognition. *Cell*, 65(1), 175-187.
- Bhavsar, H., & Panchal, M. H. (2012). A Review on Support Vector Machine for Data Classification. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 1(10), 185-189.
- Cañete-Sifuentes, L., Monroy, R., & Medina-Pérez, M. A. (2021). A Review and Experimental Comparison of Multivariate Decision Trees. *IEEE Access*, 9, 110451-110479.
- Cennet, O., & Karaçayır, H. F. (2009). Türkiye’de Elma Üretimi, Tüketimi, Pazar Yapısı ve Dış Ticareti. *Tarım Bilimleri Araştırma Dergisi*, (1), 41-49.
- Çakar, D. (2022). *Makine Öğrenmesinde Gradyan İnişi Optimizasyon Algoritmaları Üzerine*. Yüksek Lisans Tezi, Muğla Sıtkı Koçman Üniversitesi Fen Bilimleri Enstitüsü, Muğla.
- Çalışkan, A. (2019). EMG Sinyalleri İçin Hibrid Öznitelik Çıkarma Yöntemi Geliştirilmesi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 8(2), 652-664.
- Çetin, E., & Sevim, E. (2022). The Performance Comparison of the SiC and Si Mosfets Used in the 3-Phase Brushless DC Motor Drives for Electric Vehicles. *International Journal of Automotive Science And Technology*, 6(4), 331-339.

- Dragonieri, S., Schot, R., Mertens, B. J., Le Cessie, S., Gauw, S. A., Spanevello, A., & Sterk, P. J. (2007). An Electronic Nose In The Discrimination of Patients With Asthma and Controls. *Journal of Allergy and Clinical Immunology*, 120(4), 856-862.
- Duduk, N., Bekčić, F., Žebeljan, A., Vučković, N., & Vico, I. (2021). First Report of Blue Mold Caused by *Penicillium Crustosum* on Nectarine Fruit in Serbia. *Plant Disease*, 105(2), 487.
- Efe, A. A. (2006). *Elektronik Burun Teknolojisi Ve Örnek Uygulaması*. Gazi Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Eranna, G., Joshi, B.C., Runthala, D.P., Gupta, R.P. (2004). Oxide Materials for Development of Integrated Gas Sensors-A Comprehensive Review. *Critical Reviews in Solid State and Materials Sciences*, 29, 111–188.
- Faal, S., Loghavi, M., Kamgar, S., Raoufat, M. H., & Golmakani, M. T. (2019). Utilizing Pattern Recognition Methods for Detecting The Adulteration of Glucose and Fructose in Honey. *Research and Innovation in Food Science and Technology*, 7(4), 419-430.
- Gardner, J. W., Shurmer, H. V., & Tan, T. T. (1992). Application of an Electronic Nose to The Discrimination of Coffees. *Sensors and Actuators B: Chemical*, 6(1-3), 71-75.
- Gardner, J. W., & Bartlett, P. N. (1994). A Brief History of Electronic Noses. *Sensors and Actuators B: Chemical*, 18(1-3), 210-211.
- Gautam, A. K., Sharma, S., Avasthi, S., & Bhadauria, R. (2011). Diversity, Pathogenicity and Toxicology of *A. niger*: An Important Spoilage Fungi. *Research Journal of Microbiology*, 6(3), 270-280.
- Goel, N., Kunal, K., Kushwaha, A., & Kumar, M. (2023). Metal Oxide Semiconductors for Gas Sensing. *Engineering Reports*, 5(6), e12604.
- Gómez, A. H., Hu, G., Wang, J., & Pereira, A. G. (2006). Evaluation of Tomato Maturity by Electronic Nose. *Computers and Electronics in Agriculture*, 54(1), 44-52.
- Gordon, S. M., Szidon, J. P., Krotoszynski, B. K., Gibbons, R. D., & O'Neill, H. J. (1985). Volatile Organic Compounds in Exhaled Air From Patients With Lung Cancer. *Clinical chemistry*, 31(8), 1278-1282.
- Guo, Z., Huang, W., Peng, Y., Chen, Q., Ouyang, Q., & Zhao, J. (2016). Color Compensation and Comparison of Shortwave Near Infrared and Long Wave Near Infrared Spectroscopy for Determination of Soluble Solids Content of 'Fuji' apple. *Postharvest Biology and Technology*, 115, 81-90.
- Guo, Z., Guo, C., Chen, Q., Ouyang, Q., Shi, J., El-Seedi, H. R., & Zou, X. (2020). Classification for *Penicillium expansum* Spoilage and Defect in Apples by Electronic Nose Combined with Chemometrics. *Sensors*, 20(7), 2130.

- Guo, Z., Guo, C., Sun, L., Zuo, M., Chen, Q., El- Seedi, H. R., & Zou, X. (2021). Identification of The Apple Spoilage Causative Fungi and Prediction of The Spoilage Degree Using Electronic Nose. *Journal of Food Process Engineering*, 44(10), e13816.
- Hagbini, N., Bakhshipour, A., Mousanejad, S., & Zareiforoush, H. (2023). Monitoring Botrytis cinerea infection in kiwifruit using electronic nose and machine learning techniques. *Food and Bioprocess Technology*, 16(4), 749-767.
- Hasan, H.A.H., (2000). Patulin and Aflatoxin in Brown Rot Lesion of Apple Fruits and Their Regulation. *World J. Microbiol. Biotechnol.* 16, 607–612. <https://doi.org/10.1023/A:1008982511653>.
- İmrak, B., Küden, A., & Küden, A. (2010). Elma Yetiştiriciliği. *Çukurova Üniversitesi Ziraat Fakültesi*, s.16, Adana.
- İncegöl, Y., Özkan, G., İncegöl, A. C., & Taşdelen, K. (2022). Elektronik Burun Metal Oksit Yarı İletken Sensörlerin Gıda Analizlerinde Kullanımı. *Akademik Gıda*, 20(4), 454-473.
- James, D., Scott, SM, Ali, Z. ve O'hare, WT (2005). Elektronik Burun Sistemleri İçin Kimyasal Sensörler. *Microchimica Acta* , 149 , 1-17.
- Jia, W., Liang, G., Jiang, Z., & Wang, J. (2019). Advances in Electronic Nose Development for Application to Agricultural Products. *Food Analytical Methods*, 12, 2226-2240.
- Kablan, Y. (2018). *Elektronik Burun ile Farklı Kalitedeki Doğu Karadeniz Çaylarının Sınıflandırılması*, Doktora Tezi, K.T.Ü., Fen Bilimleri Enstitüsü, Trabzon.
- Kaya, K. (2016). Destek Vektör Makineleri Yardımıyla Tüketici Kredilerinin Sınıflandırılması, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Kaymak H. Ş. (2019). *Veri Zarflama Analizi ile Lineer Diskriminant Analizi'nin Karar Verme Birimlerini Sıralamalarının Karşılaştırılması*. Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Khan, A. I., Quadri, S. M. K., & Banday, S. (2021). Deep learning for apple diseases: classification and identification. *International Journal of Computational Intelligence Studies*, 10(1), 1-12.
- Kızıl, Ü., Genç, L., & Saçan, M. (2011). Elektronik Burun Sistemlerinin Tasarım İlkeleri. *Uludağ Üniversitesi Ziraat Fakültesi Dergisi*, 25(1), 109-118.
- Kızıl, Ü., & Sefa, A. K. S. U. (2018). Hava Kalitesi Ölçüm Amaçlı Kullanılan Metal-oksit Gaz Sensörlerinin Sıcaklık ve Nem Etkileşimlerinin Belirlenmesi. *ÇOMÜ Ziraat Fakültesi Dergisi*, 6(1), 91-97..
- Koçoğlu, R. (2009). Düşünsel Elektrokortikografi (ECoG) İşaretlerinin Beyin Bilgisayar Arayüzü Uygulamalarında Verimli Sınıflandırılması, K.T.Ü.,Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon.

- Kodogiannis, V. S., Lygouras, J. N., Tarczynski, A., & Chowdrey, H. S. (2008). Artificial Odor Discrimination System Using Electronic Nose and Neural Networks for The Identification of Urinary Tract Infection. *IEEE Transactions on information technology in biomedicine*, 12(6), 707-713.
- Kotsiantis, S. B. (2013). Decision Trees: A Recent Overview. *Artificial Intelligence Review*, 39, 261-283.
- Köktürk, F., (2012). *K-En Yakın Komşuluk, Yapay Sinir Ağları ve Karar Ağaçları Yöntemlerinin Sınıflandırma Başarılarının Karşılaştırılması*. Bülent Ecevit Üniversitesi Sağlık Bilimleri Enstitüsü, Malatya.
- Kumpoun, W., Motomura, Y., & Harada, Y. (2003). Inhibition of *Aspergillus* Rot by Sorbitol in Apple Fruit with Watercore Symptoms. *Postharvest biology and technology*, 29(2), 121-127.
- Küçükkömürler, S., & Karakuş, S. Ş. (2009). Elma, Sağlık ve Kültür. *Tarım Bilimleri Araştırma Dergisi*, (1), 183-186.
- Labreche, S., Bazzo, S., Cade, S., & Chanie, E. (2005). Shelf Life Determination by Electronic Nose: Application To Milk. *Sensors and Actuators B: Chemical*, 106(1), 199-206.
- Larous, L., Hendel, N., Abood, J. K., & Ghoul, M. (2007). The Growth and Production of Patulin Mycotoxin by *Penicillium expansum* on Apple Fruits and Its Control By The Use of Propionic Acid and Sodium Benzoate. *Arab Journal of Plant Protection*, 25, 123-128.
- Leunis, N., Boumans, M. L., Kremer, B., Din, S., Stobberingh, E., Kessels, A. G., & Kross, K. W. (2014). Application of an electronic nose in the diagnosis of head and neck cancer. *The Laryngoscope*, 124(6), 1377-1381.
- Luciano- Rosario, D., Keller, N. P., & Jurick, W. M. (2020). *Penicillium expansum*: Biology, Omics, and Management Tools for A Global Postharvest Pathogen Causing Blue Mould of Pome Fruit. *Molecular Plant Pathology*, 21(11), 1391-1404.
- Lima, M. A. S., Oliveira, M. D. C. F. D., Pimenta, A. T., & Uchôa, P. K. (2019). *Aspergillus niger*: A Hundred Years of Contribution to The Natural Products Chemistry. *Journal of the Brazilian Chemical Society*, 30, 2029-2059.
- Lu, L., Hu, Z., Hu, X., Li, D., & Tian, S. (2022). Electronic Tongue and Electronic Nose for Food Quality and Safety. *Food Research International*, 112214.
- Mahmoud, M. I., Dessouky, M. I., Deyab, S., & Elfouly, F. H. (2007). Comparison Between Haar and Daubechies Wavelet Transformions on FPGA Technology. *International Journal of Aerospace and Mechanical Engineering*, 1(2), 141-145.
- Mari, M., Leoni, O., Iori, R., & Cembali, T. (2002). Antifungal Vapour- Phase Activity of Allyl- Isothiocyanate Against *Penicillium Expansum* on Pears. *Plant pathology*, 51(2), 231-236.

- Meriç, B. E. (2001). *Penicillium Cinsi Bazı Küflerin Mikotoksin Oluşturma Özelliklerinin Zeytinde İncelenmesi*. i.T.Ü., Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- McCallum, J. L., Tsao, R., & Zhou, T. (2002). Factors Affecting Patulin Production by *Penicillium Expansum*. *Journal of Food Protection*, 65(12), 1937-1942.
- Moseley, P. T. (1992). Materials Selection for Semiconductor Gas Sensors. *Sensors and Actuators B: Chemical*, 6(1-3), 149-156.
- Nagle, H. T., Gutierrez-Osuna, R., & Schiffman, S. S. (1998). The How and Why of Electronic Noses. *IEEE spectrum*, 35(9), 22-31.
- Nazemi, H., Joseph, A., Park, J., & Emadi, A. (2019). Advanced Micro-And Nano-Gas Sensor Technology: A review. *Sensors*, 19(6), 1285.
- Oh, E. H., Song, H. S., & Park, T. H. (2011). Recent advances in electronic and bioelectronic noses and their biomedical applications. *Enzyme and microbial technology*, 48(6-7), 427-437.
- O'Neill, H. J., Gordon, S. M., O'Neill, M. H., Gibbons, R. D., & Szidon, J. P. (1988). A Computerized Classification Technique for Screening for The Presence of Breath Biomarkers in Lung Cancer. *Clinical chemistry*, 34(8), 1613-1618.
- Özgönen, H., & Kılıç, H. Ç. (2009). Isparta İli'nde Elmalarda Sorun Olan Hasat Sonrası Hastalıkların ve Yaygınlık Oranlarının Belirlenmesi. *Tarım Bilimleri Araştırma Dergisi*, (2), 53-60.
- Özsandıkcioglu, Ü. (2016). *Farklı Kokuların Yapay Sinir Ağları ve Bulanık Mantık Yöntemleriyle Sınıflandırılması*, Yüksek Lisans Tezi, K.T.Ü., Fen Bilimleri Enstitüsü, Trabzon.
- Öztürk, H. (2008). *Sentetik Diyabetli Nefesindeki Aseton Miktarının Elektronik Burun ve Yoğunlaştırıcı Kullanılarak Belirlenmesi*. Yüksek Lisans Tezi, Dumlupınar Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı, Kütahya .
- Öztürk, Z. Z. (2005). Yeni Bir Bilim Dalı: Koku Ölçümü. *Gyte E-bülten*, (9).
- Pearce, T. C., Schiffman, S. S., Nagle, H. T., & Gardner, J. W. (Eds.). (2006). Handbook of Machine Olfaction: Electronic Nose Technology. *John Wiley & Sons*.
- Ping, W., Yi, T., Haibao, X., & Farong, S. (1997). A Novel Method For Diabetes Diagnosis Based on Electronic Nose. *Biosensors and Bioelectronics*, 12(9-10), 1031-1036.
- Pinto, J. M. (2011). Olfaction. *Proceedings of the American Thoracic Society*, 8(1), 46-52.
- Phillips, M., Cataneo, R. N., Ditkoff, B. A., Fisher, P., Greenberg, J., Gunawardena, R., ... & Wong, C. (2003). Volatile Markers of Breast Cancer in the Breath. *The Breast Journal*, 9(3), 184-191.

- Sanaeifar, A., ZakiDizaji, H., Jafari, A., & De La Guardia, M. (2017). Early Detection of Contamination and Defect in Foodstuffs by Electronic Nose: A review. *TrAC Trends in Analytical Chemistry*, 97, 257-271.
- Sharma, A., & Paliwal, K. K. (2015). Linear Discriminant Analysis for The Small Sample Size Problem: An Overview. *International Journal of Machine Learning and Cybernetics*, 6, 443-454.
- Sonjak, S., Frisvad, J. C., & Gunde-Cimerman, N. (2005). Comparison of secondary metabolite production by *Penicillium crustosum* strains, isolated from Arctic and other various ecological niches. *FEMS microbiology ecology*, 53(1), 51-60.
- Statista, Apple production worldwide. (2021, Eylül 17).
<https://www.statista.com/statistics/961248/productionof-apples-worldwide/>
- Shykhon, M. E., Morgan, D. W., Dutta, R., Hines, E. L., & Gardner, J. W. (2004). Clinical Evaluation of the Electronic Nose in the Diagnosis of Ear, Nose and Throat İnfection: A Preliminary Study. *The Journal of Laryngology & Otology*, 118(9), 706-709.
- Şahin, M. E. (2008). *Elektronik Burun ve Temel Bileşen Analizi ile Mikroorganizmaların Saptanması*, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Dumlupınar Üniversitesi, Kütahya.
- Palacios-Cabrera, H., Taniwaki, M. H., Hashimoto, J. M., & Menezes, H. C. D. (2005). Growth of *Aspergillus ochraceus*, *A. carbonarius* and *A. niger* on Culture Media at Different Water Activities and Temperatures. *Brazilian Journal of Microbiology*, 36, 24-28.
- Pan, L., Zhang, W., Zhu, N., Mao, S., & Tu, K. (2014). Early Detection and Classification of Pathogenic Fungal Disease in Post-Harvest Strawberry Fruit By Electronic Nose And Gas Chromatography–Mass Spectrometry. *Food Research International*, 62, 162-168.
- Partal, T., Kahya, E., & Cıgızoğlu, K. (2011). Yağış Verilerinin Yapay Sinir Ağları ve Dalgacık Dönüşümü Yöntemleri İle Tahmini. *İTÜDERGİSİ*, 7(3).
- Qiao, J., Su, G., Liu, C., Zou, Y., Chang, Z., Yu, H., ... & Guo, R. (2022). Study on the application of electronic nose technology in the detection for the artificial ripening of crab apples. *Horticulturae*, 8(5), 386.
- Qin, C., Song, S., Huang, G., & Zhu, L. (2015). Unsupervised neighborhood component analysis for clustering. *Neurocomputing*, 168, 609-617.
- Qin, Y., Jia, W., Sun, X., & Haolin, L. V. (2023). Development of electronic nose for detection of micro-mechanical damages in strawberries. *Frontiers in Nutrition*, 10.
- Roberts, T. A., Tompkin, R. B., & Baird-Parker, A. C. (1996). Microorganisms in Foods 5: Microbiological Specifications of Food Pathogens. *Chapman & Hall*.

- Russo, M., di Sanzo, R., Cefaly, V., Carabetta, S., Serra, D., & Fuda, S. (2013). Non-Destructive Flavour Evaluation of Red Onion (*Allium Cepa* L.) Ecotypes: An Electronic-Nose-Based Approach. *Food chemistry*, 141(2), 896-899.
- Saraoğlu, H. M. (2008). Elektronik Burun Teknolojisi ve Uygulama Alanları. *Akademik Bilişim 2008*, Çanakkale Onsekiz Mart Üniversitesi, Çanakkale, 30 Ocak-1 Şubat 2008.
- Schuster, E., Dunn-Coleman, N., Frisvad, J. C., & Van Dijck, P. W. (2002). On the Safety of *Aspergillus niger*—a Review. *Applied microbiology and biotechnology*, 59, 426-435.
- Shephard, G. S., & Leggott, N. L. (2000). Chromatographic Determination of the Mycotoxin Patulin in Fruit and Fruit Juices. *Journal of Chromatography A*, 882(1-2), 17-22.
- Teixeira, R. C., Rodríguez, M., de Romero, N. J., Bruins, M., Gómez, R., Yntema, J. B., ... & Magis-Escurra, C. (2017). The Potential of a Portable, Point-Of-Care Electronic Nose to Diagnose Tuberculosis. *Journal of Infection*, 75(5), 441-447.
- Tozlu, B. H., (2014). *Elektronik Burunla Çay Fermantasyonu Denetimi*, Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Turan, İ. (2012). Temel İstatistik. SPSS Analiz Menüsü, 1-10.
- Tuncer, T., Dogan, S., Pławiak, P., & Acharya, U. R. (2019). Automated arrhythmia detection using novel hexadecimal local pattern and multilevel wavelet transform with ECG signals. *Knowledge-Based Systems*, 186, 104923.
- TÜP, (2022). Tarım Ürünleri Piyasaları: <https://arastirma.tarimorman.gov.tr/tepge/Menu/27/Tarim-Urunleri-Piyasalari> adresinden alınmıştır.
- Uçar, Ö. (2013). Ankara İli Üniversite Öğrencileri Koku Profilinin Belirlenmesi, Doktora Tezi, Gazi Üniversitesi, Eğitim Bilimleri Enstitüsü, Giyim Endüstrisi ve Giyim Sanatları Anabilim Dalı, Ankara.
- Özalp, R. & Uçar, A. (2016). Meyve Kokularının Algılanması ve Sınıflandırılması İçin Düşük Maliyetli Elektronik Burun Tasarımı. Akıllı Sistemlerde Yenilikler ve Uygulamaları (ASYU) Sempozyumu, Bildiriler Kitabı II, s. 75-79. Düzce.
- Webb, G. I., Keogh, E., & Miikkulainen, R. (2010). Naïve Bayes. *Encyclopedia of machine learning*, 15(1), 713-714.
- Wickramasinghe, I., & Kalutarage, H. (2021). Naive Bayes: Applications, Variations and Vulnerabilities: A Review Of Literature With Code Snippets for Implementation. *Soft Computing*, 25 (3), 2277-2293.
- Williams, H., & Pembroke, A. (1989). Sniffer Dogs in the Melanoma Clinic?. *The Lancet*, 333(8640), 734.

- Wilson, A. D., & Baietto, M. (2009). Applications and Advances in Electronic-Nose Technologies. *Sensors*, 9(7), 5099-5148.
- Wilson, A. D. (2013). Diverse Applications of Electronic-Nose Technologies in Agriculture And Forestry. *Sensors*, 13(2), 2295-2348.
- Yağanoğlu, M., Bozkurt, F., & Günay, F. B. (2014). EEG Tabanlı Beyin-Bilgisayar Arayüzü Sistemlerinde Öznitelik Çıkarma Yöntemleri. *Mühendislik Bilimleri ve Tasarım Dergisi*, 2(3), 313-318.
- Yağmur, N. (2020). *Gradyan İniş Yöntemi ve Kontrol Sistemlerinde Uygulamaları*. Yüksek Lisans Tezi, İnönü Üniversitesi Fen Bilimleri Enstitüsü, Malatya.
- Yavuz, E. (2017) *Beyin Bilgisayar Arayüzü İşaretlerinin Farklı Zaman Dilimlerinde Çıkarılmış Özniteliklerle Sınıflandırma Doğruluğunun Arttırılması*, K.T.Ü., Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon
- Yavuzer, E. (2021). Determination of Fish Quality Parameters with Low Cost Electronic Nose. *Food Bioscience*, 41, 100948.
- Yılmaz, G., Mete, N. F., Umusalama, U., & Aydemir, Ö. (2020). Dalgacık Dönüşümü ve Özbağlanım Model Parametreleri Öznitelikleri ile Otomobil Motor Seslerinden Arıza Tespiti. *Journal of Investigations on Engineering and Technology*, 3(2), 48-54.
- Zhao, C., Ma, J., Jia, W., Wang, H., Tian, H., Wang, J., & Zhou, W. (2022). An Apple Fungal Infection Detection Model Based on BPNN Optimized by Sparrow Search Algorithm. *Biosensors*, 12(9), 692.
- Zappa, D., Galstyan, V., Kaur, N., Arachchige, H. M. M., Sisman, O., & Comini, E. (2018). Metal Oxide-Based Heterostructures for Gas Sensors. A review. *Analytica Chimica Acta*, 1039, 1-23.
- Žebeljan, A., Vico, I., Duduk, N., Žiberna, B., & Krajnc, A. U. (2021). Profiling Changes in Primary Metabolites and Antioxidants During Apple Fruit Decay Caused by *Penicillium crustosum*. *Physiological and Molecular Plant Pathology*, 113, 101586.
- Zhang, S., Li, X., Zong, M., Zhu, X., & Cheng, D. (2017). Learning K for KNN Classification. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 8(3), 1-19.
- Zigic, L., & Kecman, V. (2014). Variants and Performances of Novel Direct Learning Algorithms for L2 Support Vector Machines. In *Artificial Intelligence and Soft Computing: 13th International Conference, ICAISC 2014, Zakopane, Poland, June 1-5, 2014, Proceedings, Part II* 13 (pp. 82-91). Springer International Publishing.
- Zou, X., Wang, C., Luo, M., Ren, Q., Liu, Y., Zhang, S., ... & Su, S. W. (2022). Design of electronic nose detection system for apple quality grading based on computational fluid dynamics simulation and K-nearest neighbor support vector machine. *Sensors*, 22(8), 2997.

ÖZGEÇMİŞ

Elektrik-Elektronik Mühendisi Esra KOCAMANOĞLU, ilköğrenimini Trabzon Fatih İlkokulu'nda, Liseyi Tefvik Serdar Anadolu Lisesi'nde tamamladı. Esra KOCAMANOĞLU, 2013 yılında Karadeniz Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümünü kazandı. 2018 yılında “Elektrik-Elektronik Mühendisi” unvanı ile lisans eğitimini tamamladı. 2020 yılında Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında yüksek lisans öğrenimine başladı. 2020 yılında Recep Tayyip Erdoğan Üniversitesi'nde pedagojik formasyon eğitimini tamamladı. 2021-2022 yılları arasında kendi alanında özel sektörde çalıştı. 2023 yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalına Araştırma Görevlisi olarak atanan Kocamanoğlu halen bu alanda görevini sürdürmektedir.

Kocamanoğlu, E., Aydemir, Ö., (2022). Determination of Fungus Infected Apples by Using Electronic Nose. *4th International Conference on Advanced Engineering Technologies (ICADET)*, *Bildiriler Kitabı*, s.530-537. Bayburt.