

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KARMA YAPILI İKİLİ KARAR AĞACI
TABANLI KOKU TANIMA SİSTEMİ

DOKTORA TEZİ

Elektronik. Yük. Müh. Selda GÜNEY

TEMMUZ 2013
TRABZON

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KARMA YAPILI İKİLİ KARAR AĞACI
TABANLI KOKU TANIMA SİSTEMİ

Elektronik. Yük. Müh. Selda GÜNEY

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 21.06.2013
Tezin Savunma Tarihi : 16.07.2013

Tez Danışmanı : Yrd. Doç. Dr. Ayten ATASOY

Trabzon 2013

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalında
Selda GÜNEY tarafından hazırlanan

**KARMA YAPILI İKİLİ KARAR AĞACI
TABANLI KOKU TANIMA SİSTEMİ**

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 25/06/2013 gün ve 1511 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Tülay YILDIRIM

Üye : Prof. Dr. İsmail H. ALTAŞ

Üye : Prof. Dr. Vasif V. NABİYEV

Üye : Yrd. Doç. Dr. Ayten ATASOY

Üye : Yrd. Doç. Dr. Yusuf SEVİM

.....
.....
.....
.....
.....

Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

Biyolojik burundan esinlenerek geliştirilen, gün geçtikçe kullanım alanı yaygınlaşan ve “Elektronik Burun” olarak adlandırılan yapay koku algılama sistemlerinin, iyileştirilmesi çalışmaları günümüzde de devam etmektedir. Biyolojik koku algılama sisteminin hala anlaşılammış olması, biyolojik buruna yakın bir elektronik burunun yapılamamasının sebeplerinden biridir. Bu tez çalışmasında, elektronik burun kullanılarak geliştirilen koku tanıma sisteminin sorunlarına değinilmiş ve iyileştirilmeye çalışılmıştır. Elektronik Burunun disiplinler arası bir konu olmasından dolayı, farklı bilim dallarından araştırma grupları bu konu üzerine çalışmakta ve geliştirilen bulgular sayesinde kokunun gelişimi hız kazanmaktadır. Ülkemizde “Elektronik Burun” alanına değinen nadir doktora çalışmalarından birini tamamlamış olmanın gururunu taşımaktayım.

Bu gururu yaşamama sebep olan, tez süresince çalışmalarımın her aşamasında yanımda olan, vaktini ayıran, bilgi, tecrübe ve desteğini esirgemeyen, motivasyonum düştüğünde, beni yeniden cesaretlendiren, değerli danışmanım Yrd. Doç Dr. Ayten ATASOY’a, değerli danışmanlığından dolayı teşekkürü bir borç bilirim.

Ayrıca bu meşakkatli süreçte çalışmama fikirleriyle destek ve yön veren, değerli tez izleme hocalarım Prof. Dr. Vasif NABIYEV ve Prof. Dr. İsmail H. ALTAŞ’a teşekkürlerimi sunarım.

Bu çalışmada gerçekleştirdiğim balık tazeliği deneyleri için yardımlarını ve bu konudaki bilgi birikimlerini esirgemeyen Denizer Balıkçılık çalışanlarına teşekkür ederim.

Bu çalışmayı mali yönden destekleyen KTÜ Bilimsel Araştırma Fonu’na ve TÜBİTAK’a da çok teşekkür ederim.

Son olarak, çalışmalarım süresince her an yanımda olan, desteğini ve hoşgörüsünü eksik etmeyen, değerli eşim Göksel GÜNEY’e, varlığı ile hayatıma renk ve güzellik katan biricik oğlum Berke’ye, sadece beni yetiştirmekle kalmayıp bu zaman zarfında oğlumu da yetiştirmemde desteğini esirgemeyen, hakkını hiçbir zaman ödeyemeyeceğim biricik annem Ayşe KUL’a, hoşgöruları ve manevi desteklerinden dolayı sevgili babam Mustafa KUL, kardeşim Oktay KUL ve ailemin tüm fertlerine sonsuz teşekkürlerimi sunarım.

Selda GÜNEY

Trabzon 2013

TEZ BEYANNAMESİ

Doktora Tezi olarak sunduđum ‘‘Karma Yapılı İkili Karar Ađacı Tabanlı Koku Tanıma Sistemi’’ bařlıklı bu alıřmayı bařtan sona kadar danıřmanım Yrd. Do. Dr. Ayten ATASOY’un sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, bařka kaynaklardan aldıđım bilgileri metinde ve kaynakada eksiksiz olarak gösterdiđimi, alıřma sürecinde bilimsel arařtırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya ıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 16/07/2013

Selda GÜNEY

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ.....	XVII
SEMBOLLER DİZİNİ	XIX
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Koku Uzayı.....	3
1.3. Biyolojik Koku Algılama Sistemi	5
1.4. Elektronik Burun	6
1.4.1. Algılayıcı Birim.....	7
1.4.1.1. Elektro-Kimyasal Sensörler.....	8
1.4.1.2. Isıl Sensörler	10
1.4.1.3. Optik Sensörler	10
1.4.1.4. Gravimetrik Sensörler.....	11
1.4.2. Dönüştürücü Birim	12
1.4.3. Elektronik Birim	13
1.4.4. İşaret Koşullama Birimi.....	13
1.4.5. İşaret Ön İşleme Birimi	14
1.4.5.1. Referans Düzeltme	14
1.4.5.2. Boyut İndirgeme	16
1.4.5.2.1. Öznitelik Çıkarma.....	17
1.4.5.2.2. Öznitelik Alt Kümesi Seçimi.....	19
1.4.5.3. Normalizasyon.....	19
1.4.6. Örüntü Tanıma Birimi	20
1.4.6.1. Bayes Sınıflandırıcılar	23
1.4.6.2. Doğrusal Ayırma Analizi.....	24
1.4.6.3. Destek Vektör Makinaları	25

1.4.6.4.	En Yakın K-Komşu Sınıflandırıcı	26
1.5.	Tez Çalışmasının Amacı ve Literatüre Katkıları	26
1.6.	Tez Çalışmasının Kapsamı ve Organizasyonu	27
2.	YAPILAN ÇALIŞMALAR.....	29
2.1.	Elektronik Burun Deney Düzeneği.....	30
2.1.1.	Örnek Koku Haznesi	31
2.1.2.	Koku İletim Sistemi.....	32
2.1.3.	Akış Kontrol Sistemi	34
2.1.4.	Koku Sensör Haznesi.....	34
2.1.4.1.	Gaz Sensörleri.....	35
2.1.4.2.	Sıcaklık ve Nem Sensörü.....	39
2.1.5.	Sensör Arayüz Kartı	40
2.1.6.	Kontrol Arayüz Kartı ve Soğutucu Fan	40
2.1.7.	Veri Elde Etme Kartı	41
2.2.	Deney Süreci.....	43
2.3.	Kullanılan Veri Tabanları	44
2.3.1.	n-Butanol Gazına Ait Konsantrasyon Veri Tabanı (VERİ1).....	44
2.3.2.	Birincil Kokulara Ait Veri Tabanı (VERİ2).....	45
2.3.3.	Balık Kokularına Ait Veri Tabanı (VERİ3)	46
2.3.4.	Farklı Balık Kokularına Ait Veri Tabanı (VERİ4).....	47
2.4.	İşaret Ön İşleme	48
2.4.1.	Referans Gazın Çıkartılması.....	49
2.4.2.	Referans Düzeltme	50
2.4.3.	Öznitelik Çıkarma.....	51
2.4.3.1.	Öznitelik Olarak Parametre Çıkartma Yaklaşımı	51
2.4.3.2.	Alt Örnekleme Yöntemi ile Öznitelik Çıkarma Yaklaşımı	55
2.4.4.	Normalizasyon.....	56
2.4.5.	Öznitelik Seçme.....	56
2.5.	Sınıflandırma	57
2.5.1.	Bayes Sınıflandırma Algoritması	58
2.5.2.	Doğrusal Ayırma Analizi Algoritması	60
2.5.3.	Destek Vektör Makinası Algoritması	61
2.5.4.	k En Yakın Komşuluk Algoritması	65
2.5.6.	Önerilen Sınıflandırma Yaklaşımı	67

2.6.	Sınıflandırma Performans Ölçütleri.....	74
3.	BULGULAR	77
3.1.	Ham Sensör İşaretlerine Ait Deneysel Sonuçlar	77
3.1.1.	VERİ1'e Ait İşaretler.....	77
3.1.2.	VERİ2'ye Ait İşaretler.....	80
3.1.3.	VERİ'e Ait İşaretler.....	84
3.1.4.	VERİ4'e Ait İşaretler.....	87
3.2.	İşaret Ön İşleme İşlemine Tabi Olan Sensör İşaretlerine Ait Deneysel Bulgular	89
3.2.1.	VERİ2 İçin Ön İşleme İşlemi ve Deneysel Bulguları	89
3.2.2.	VERİ3 İçin Ön İşleme İşlemi ve Deneysel Bulguları	99
3.2.3.	VERİ4 İçin Ön İşleme İşlemi ve Deneysel Bulguları	106
3.3.	Öznitelikler ile İlgili Elde Edilen Bulgular.....	113
3.3.1.	VERİ2'ye Ait Öznitelikler ile İlgili Elde Edilen Bulgular	113
3.3.2.	VERİ3'e Ait Öznitelikler ile İlgili Elde Edilen Bulgular	128
3.3.3.	VERİ4'e Ait Öznitelikler ile İlgili Elde Edilen Bulgular	138
3.4.	Sınıflandırma Bulguları	147
3.4.1.	VERİ1 İçin Sınıflandırma Bulguları.....	148
3.4.2.	VERİ2 İçin Sınıflandırma Bulguları.....	151
3.4.3.	VERİ3 İçin Sınıflandırma Bulguları.....	153
3.4.4.	VERİ4 İçin Sınıflandırma Bulguları.....	157
4.	SONUÇLAR.....	160
5.	ÖNERİLER	164
6.	KAYNAKLAR.....	166

ÖZGEÇMİŞ

Doktora Tezi

ÖZET

KARMA YAPILI İKİLİ KARAR AĞACI TABANLI KOKU TANIMA SİSTEMİ

Selda GÜNEY

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Müh. Anabilim Dalı
Danışman: Yrd. Doç. Dr. Ayten ATASOY
2013, 179 Sayfa

Çalışma kapsamında elektronik burun ile koku tanıma sistemlerinin sorunları irdelenmekte ve bu sorunlara çözüm getirecek şekilde yeni hibrit yöntemler önerilmektedir. Tezde 4 farklı veri tabanı kullanılmaktadır. Bunlardan biri hazır veri tabanı iken, diğerleri tez kapsamında oluşturulan elektronik burundan elde edilen veri tabanlarıdır. Bu 4 veri tabanı sırasıyla n-butanol gazının farklı konsantrasyon değerlerinden, 11 birbirinden farklı kokudan, istavrit balığının farklı günlerine ait kokularından ve 3 farklı balık (istavrit, hamsi ve mezgıt) kokularından oluşmaktadır. Elektronik burunda kullanılan sensörlerin en büyük problemi olan sensör kaymalarına çözüm önerilmektedir. Önerilen yöntem, uygulanan örnek kokular için elde edilen sensör işaretlerinden, ortam kokusu için elde edilen sensör işaretini çıkartarak elde edilen fark işaretini örüntü tanıma birimine uygulamaktır. Literatürden farklı olarak yapılan bu işaret ön işleme; sensör kaymalarını 3 veri tabanı için de azaltmaktadır. Buna ilaveten farklı öznitelik çıkarma yöntemleri kıyaslanmaktadır. Sensör verisi için sınıflandırma performansını en fazla arttıran yöntem alt örnekleme yöntemi olarak belirlenmiştir. Sınıflandırma birimi için ise öznitelik seçme işlemini yapısında bulunduran, literatürden farklı olan ikili karar ağacı tabanlı bir yöntem önerilmiştir. İkili karar ağacı tabanlı yöntem problemi parçalara ayırmaktadır. Her bir parçanın sınıflandırmasında o veriyi en iyi sınıflandıracak öznitelikler çıkartılan öznitelikler arasından ve en iyi sınıflandırma yöntemi Destek Vektör Makinaları, k-En Yakın Komşuluk, Doğrusal Ayırma Analiz ve Bayes sınıflandırma yöntemleri arasından seçilmektedir. Önerilen yöntem tüm veri tabanlarına uygulandığında sınıflandırma performansını arttırmaktadır.

Anahtar Kelimeler: Elektronik burun işaret analizi, Öznitelik çıkarma, Öznitelik seçme, Sınıflandırma, k-EYK, DAA, DVM, Bayes Sınıflandırma, İkili karar ağacı yapısı.

PhD. Thesis

SUMMARY

A HYBRID BINARY DECISION TREE BASED ODOR RECOGNITION SYSTEM

Selda GÜNEY

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Asst. Prof. Dr. Ayten ATASOY
2013, 179 Pages

In the context of the study, the electronic nose and the problems that exist in the odor recognition systems are studied and solutions to those problems with novel hybrid methods are proposed. In this thesis, four different databases are used. While one of them is a database from literature, the other three databases are produced by the electronic nose which is built during the thesis. These four databases consist of different concentration values of n-butananes, 11 different odors, odors of horse mackerel in different days and three different fish (horse mackerel, anchovy and whiting) odors, respectively. A solution to the sensor drift which is the main problem in electronic nose is proposed. The proposed method is to apply the difference signal which is obtained by subtracting the sensor signal of the atmospheric (environment) odor from the sensor signals which are obtained by the applied sample odors. This preprocessing which is different from the literature is decreasing the sensor aliasing for all three databases. In addition, different feature extraction methods are compared. For the sensor data, the sub-sampling method is found to be the method which gets maximum classification performance. For the classification, apart from the literature, a new method which is based on the binary decision tree is proposed. This binary decision tree divides the problem into pieces. In the classification of every piece, the best features are chosen from the extracted features and the best classification method is chosen from the applied Support Vector Machines, k-Nearest Distance, Linear Discriminant Analysis and Bayesian classification methods. The proposed method increases the classification performance when applied to all databases.

Key Words: Signal processing for electronic nose, Feature extraction, Feature selection, Classification, k-NN, LDA, SVM, Bayes classifier, Binary decision tree structure.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Henning piramidi.....	4
Şekil 1.2. Koku algılama hücresinin genel yapısı	5
Şekil 1.3. Koku algılama sistemi	6
Şekil 1.4. Elektronik burun biyolojik burun ilişkisi	7
Şekil 1.5. 8 sensöre limon kokusu uygulandığında elde edilen ham işaret	15
Şekil 1.6. 8 sensöre limon kokusu uygulandığında elde edilen ham işaretin fark alma manipülasyonu ile düzeltilmiş şekli	16
Şekil 1.7. Sensörlerden elde edilen işaretin işaret işleme aşamaları	21
Şekil 1.8. Sınıflandırma yöntemleri.....	22
Şekil 1.9. Doğrusal olarak birbirinden ayrılabilen veriler	25
Şekil 2.1. E-burun deney düzeneğinin blok şeması.....	30
Şekil 2.2. a) İki boyunlu cam balon b) Cam kavanoz	31
Şekil 2.3. Koku iletim sistemi blok şeması	32
Şekil 2.4. Koku iletim sistemi ve elemanları a) plastik boru, b) T pirinç bağlayıcı, teflon boru ve Solenoit vana, c) hava pompası.....	33
Şekil 2.5. Akış kontrol sistemi elemanları a) KAK b) Kütle akış kontrol istasyonu.....	34
Şekil 2.6. E-burunda kullanılan sensör haznesi a) teknik resmi b) fotoğrafı.....	35
Şekil 2.7. a) TGS8xx serisi gaz sensörleri b) TGS 2xxx [133].	36
Şekil 2.8. a) TGS 8xx serisi b) TGS 2xxx serisi gaz sensörlerinin elektriksel eşdeğer devresi c) E-burunda kullanılan tüm sensörler	37
Şekil 2.9. a) Sıcaklık sensörü b) Sıcaklık sensörü elektriksel eşdeğer devresi	39
Şekil 2.10. Sensör arayüz devresi.....	40
Şekil 2.11. Solenoit vana kontrol devresi	41
Şekil 2.12. a) DAQ 6259 veri elde etme kartı [135] b) DAQ veri akış blok şeması	42
Şekil 2.13. Alpha MOS Fox 3000	45
Şekil 2.14. İşaret işleme aşamaları	48
Şekil 2.15. Örnek bir sensör işareti	52
Şekil 2.16. Doğrusal ayrılabilen veri görünümü	61
Şekil 2.17. k-NN sınıf ayrımı gösterimi	66
Şekil 2.18. VERİ1 için önerilen yöntemde ikili karar ağacının yapısı.....	69

Şekil 2.19.	VERİ2 için önerilen yöntemle oluşturulan ikili karar ağacının yapısı.....	71
Şekil 2.20.	VERİ3 için önerilen yöntemle oluşturulan ikili karar ağacının yapısı.....	72
Şekil 2.21.	VERİ4 için önerilen yöntemle oluşturulan ikili karar ağacının yapısı.....	74
Şekil 3.1.	VERİ1'deki farklı konsantrasyon değerleri için 12 sensör değerinin değişimi	78
Şekil 3.2.	Pozitif yönde artış gösteren sensörlere ait sensör direnç oranı ile konsantrasyonun değişim grafiği	79
Şekil 3.3.	Negatif yönde artış gösteren sensörlere ait sensör direnç oranı ile konsantrasyonun değişim grafiği	79
Şekil 3.4.	Limon kokusu için 8 sensörden elde edilen ham işaretler	80
Şekil 3.5.	Aseton kokusu için 8 sensörden elde edilen ham işaretler.....	81
Şekil 3.6.	Naftalin kokusu için 8 sensörden elde edilen ham işaretler	81
Şekil 3.7.	Gül suyu kokusu için 8 sensörden elde edilen ham işaretler.....	81
Şekil 3.8.	Oje kokusu için 8 sensörden elde edilen ham işaretler	82
Şekil 3.9.	Melekotu kökü kokusu için 8 sensörden elde edilen ham işaretler.....	82
Şekil 3.10.	Nane kokusu için 8 sensörden elde edilen ham işaretler.....	82
Şekil 3.11.	Yumurta kokusu için 8 sensörden elde edilen ham işaretler	83
Şekil 3.12.	Çürük yumurta kokusu için 8 sensörden elde edilen ham işaretler.....	83
Şekil 3.13.	Sarımsak kokusu için 8 sensörden elde edilen ham işaretler	83
Şekil 3.14.	Çimen kokusu için 8 sensörden elde edilen ham işaretler	84
Şekil 3.15.	1 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler.....	85
Şekil 3.16.	3 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler.....	85
Şekil 3.17.	5 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler.....	85
Şekil 3.18.	7 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler.....	86
Şekil 3.19.	9 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler.....	86
Şekil 3.20.	11 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler.....	86
Şekil 3.21.	13 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler.....	87
Şekil 3.22.	İstavrit kokusu için sensörlerden elde edilen ham işaretler.....	88
Şekil 3.23.	Hamsi kokusu için sensörlerden elde edilen ham işaretler	88
Şekil 3.24.	Mezgit kokusu için sensörlerden elde edilen ham işaretler.....	88
Şekil 3.25.	Naftalin kokusu için 8 sensörün iletkenlik değişimi	90
Şekil 3.26.	Naftalin kokusu için ortam havası çıkarılan sensör işaretleri	90
Şekil 3.27.	Naftalin kokusu için referans düzeltme uygulanan sensör işaretleri.....	91
Şekil 3.28.	Çürük yumurta kokusu için 8 sensörün iletkenlik değişimi.....	91
Şekil 3.29.	Çürük yumurta kokusu için ortam havası çıkarılan sensör işaretleri	92

Şekil 3.30.	Çürük yumurta kokusu için referans düzeltme uygulanan sensör işaretleri.....	92
Şekil 3.31.	Çimen kokusu için 8 sensörün iletkenlik değişimi.....	92
Şekil 3.32.	Çimen kokusu için ortam havası çıkarılan sensör işaretleri.....	93
Şekil 3.33.	Çimen kokusu için referans düzeltme uygulanan sensör işaretleri	93
Şekil 3.34.	TGS 880 sensörünün a) limon, aseton ve oje b) naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta ve sarımsak için işaret ön işleme uygulanan işaretleri.....	94
Şekil 3.35.	a) TGS 826 sensörünün limon, aseton ve oje için b) TGS 826 sensörünün naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta ve sarımsak için işaret ön işleme uygulanan işaretleri.....	95
Şekil 3.36.	a) TGS 2610 sensörünün limon, aseton ve oje için b) TGS 2610 sensörünün naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta ve sarımsak için işaret ön işleme uygulanan işaretleri.....	96
Şekil 3.37.	a) TGS 2602 sensörünün limon, aseton ve oje için b) TGS 2602 sensörünün naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta ve sarımsak için işaret ön işleme uygulanan işaretleri.....	97
Şekil 3.38.	a) TGS 2104 sensörünün limon, aseton ve oje için b) TGS 2104 sensörünün naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta, çimen ve sarımsak için işaret ön işleme uygulanan işaretleri.....	98
Şekil 3.39.	1 günlük istavrit kokusu için ortam havası çıkarılan sensör işaretleri	99
Şekil 3.40.	1 günlük istavrit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri.....	100
Şekil 3.41.	1 günlük istavrit kokusu için referans düzeltme uygulanan sensör işaretleri.....	100
Şekil 3.42.	7 günlük istavrit kokusu için ortam havası çıkarılan sensör işaretleri	101
Şekil 3.43.	7 günlük istavrit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri.....	101
Şekil 3.44.	7 günlük istavrit kokusu için referans düzeltme uygulanan sensör işaretleri.....	102
Şekil 3.45.	11 günlük istavrit kokusu için ortam havası çıkarılan sensör işaretleri	102
Şekil 3.46.	11 günlük istavrit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri.....	103
Şekil 3.47.	11 günlük istavrit kokusu için referans düzeltme uygulanan sensör işaretleri.....	103
Şekil 3.48.	TGS 880'nin farklı günler için istavrit kokularına verdiği sensör cevapları	104
Şekil 3.49.	TGS 2610'nun farklı günler için istavrit kokularına verdiği sensör cevapları	104
Şekil 3.50.	TGS 2602'nin farklı günler için istavrit kokularına verdiği sensör cevapları	105

Şekil 3.51.	TGS 2104'ün farklı günler için istavrit kokularına verdiği sensör cevapları	105
Şekil 3.52.	İstavrit kokusu için ortam havası çıkarılan sensör işaretleri	106
Şekil 3.53.	İstavrit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri	106
Şekil 3.54.	İstavrit kokusu için referans düzeltme uygulanan sensör işaretleri.....	107
Şekil 3.55.	Hamsi kokusu için ortam havası çıkarılan sensör işaretleri	107
Şekil 3.56.	Hamsi kokusu için iletkenliğe dönüştürülmüş sensör işaretleri	108
Şekil 3.57.	Hamsi kokusu için referans düzeltme uygulanan sensör işaretleri	108
Şekil 3.58.	Mezgit kokusu için ortam havası çıkarılan sensör işaretleri	109
Şekil 3.59.	Mezgit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri	109
Şekil 3.60.	Mezgit kokusu için referans düzeltme uygulanan sensör işaretleri.....	110
Şekil 3.61.	TGS 880'in farklı balık kokularına verdiği sensör cevapları.....	110
Şekil 3.62.	TGS 825'in farklı balık kokularına verdiği sensör cevapları.....	111
Şekil 3.63.	TGS 826'nın farklı balık kokularına verdiği sensör cevapları.....	111
Şekil 3.64.	TGS 2620'nin farklı balık kokularına verdiği sensör cevapları.....	112
Şekil 3.65.	TGS 2602'nin farklı balık kokularına verdiği sensör cevapları.....	112
Şekil 3.66.	TGS 2104'nin farklı balık kokularına verdiği sensör cevapları.....	113
Şekil 3.67.	Naftalin için 8 sensör ile farklı ölçümlerden elde edilen öznelikler	114
Şekil 3.68.	Gülsuyu için 8 sensör ile farklı ölçümlerden elde edilen öznelikler.....	114
Şekil 3.69.	Melekotu kökü için 8 sensör ile farklı ölçümlerden elde edilen öznelikler.....	115
Şekil 3.70.	Nane için 8 sensör ile farklı ölçümlerden elde edilen öznelikler	115
Şekil 3.71.	Naftalin için 8 sensör ile farklı ölçümlerden elde edilen öznelikler	116
Şekil 3.72.	Gülsuyu için 8 sensör ile farklı ölçümlerden elde edilen öznelikler.....	116
Şekil 3.73.	Melekotu için 8 sensör ile farklı ölçümlerden elde edilen öznelikler	117
Şekil 3.74.	Nane için 8 sensör ile farklı ölçümlerden elde edilen öznelikler.....	117
Şekil 3.75.	Yumurta kokusu için a) ilk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özneliklerin radar çizimi	118
Şekil 3.76.	Sarımsak kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özneliklerin radar çizimi	118
Şekil 3.77.	Çimen kokusu için a) ilk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özneliklerin radar çizimi.....	119

Şekil 3.78.	Naftalin kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin radar çizimi	119
Şekil 3.79.	Nane kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin radar çizimi	120
Şekil 3.80.	Nane kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin radar çizimi	121
Şekil 3.81.	Sarımsak kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin radar çizimi	122
Şekil 3.82.	Çimen kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin radar çizimi	123
Şekil 3.83.	Yumurta kokusu için a) ilk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin tüm veriler için dağılımı	124
Şekil 3.84.	Çürük yumurta kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin tüm veriler için dağılımı	125
Şekil 3.85.	Çimen kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin tüm veriler için dağılımı	126
Şekil 3.86.	Gülsuyu kokusu için a) TGS 880 ve TGS 825 b) TGS 830 ve TGS 826 c) TGS 2610 ve TGS 2620 d) TGS 2602 ve TGS 2104 sensörlerinden elde edilen öz niteliklerin tüm gülsuyu kokusu verileri için dağılımı.....	127
Şekil 3.87.	Melekotu kokusu için a) TGS 880 ve TGS 825 b) TGS 830 ve TGS 826 c) TGS 2610 ve TGS 2620 d) TGS 2602 ve TGS 2104 sensörlerinden elde edilen öz niteliklerin tüm veriler için dağılımı.....	128
Şekil 3.88.	Maksimum değer öz nitelik olarak alındığında 5 günlük istavrit koku örüntüsü.....	129
Şekil 3.89.	Maksimum değer öz nitelik olarak alındığında 5 günlük istavrit koku örüntüsü.....	130
Şekil 3.90.	İntegral alma öz nitelik olarak seçildiğinde 5 günlük istavrit kokusunun örüntüsü	130
Şekil 3.91.	İntegral alma öz nitelik olarak seçildiğinde 7 günlük istavrit kokusunun örüntüsü	130
Şekil 3.92.	Ortalama değer, standart sapma, basıklık ve çarpıklık katsayısı öz nitelik olarak seçildiğinde a) ilk 4 sensör b) son 4 sensör için 5 günlük istavrit kokusunun örüntüsü	131

Şekil 3.93.	Ortalama değer, standart sapma, basıklık ve çarpıklık katsayısı öznelik olarak seçildiğinde a) ilk 4 sensör b) son 4 sensör için 7 günlük istavrit kokusunun örüntüsü	131
Şekil 3.94.	5 günlük istavrit kokusu için a) TGS 880 ve 825 b) TGS 830 ve 826 c) TGS 2620 ve 2610 d)TGS 2602 ve 2104 sensörlerinden çıkartılan öznelikler.....	132
Şekil 3.95.	7 günlük istavrit kokusu için a) TGS 880 ve 825 b) TGS 830 ve 826 c) TGS 2620 ve 2610 d)TGS 2602 ve 2104 sensörlerinden çıkartılan öznelikler.....	133
Şekil 3.96.	5 günlük istavrit kokusu için elde edilen özneliklerin dağılımı a) ilk 4 sensör için b) son 4 sensör için.....	134
Şekil 3.97.	7 günlük istavrit kokusu için elde edilen özneliklerin dağılımı a) ilk 4 sensör için b) son 4 sensör için.....	135
Şekil 3.98.	5 günlük istavrit için a)TGS 880-825 b) TGS 830-826 c) TGS 2620-2620 d)TGS 2602-2104 sensörleri için alt örnekleme ile elde edilen öznelikler.....	136
Şekil 3.99.	7 günlük istavrit için a)TGS 880-825 b) TGS 830-826 c) TGS 2620-2620 d)TGS 2602-2104 sensörleri için alt örnekleme ile elde edilen öznelikler.....	136
Şekil 3.100.	Öznelik olarak maksimum değerleri alındığında 3 günlük a) istavrit b) hamsi c) mezgıt kokusu örüntüleri.....	138
Şekil 3.101.	Öznelik olarak integral değerleri alındığında 3 günlük a) istavrit b) hamsi c) mezgıt kokusu örüntüleri	139
Şekil 3.102.	Öznelik olarak ortalama değeri, standart sapma, basıklık katsayısı ve çarpıklık katsayısı değerleri alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük istavrit kokusu örüntüsü	140
Şekil 3.103.	Öznelik olarak ortalama değeri, standart sapma, basıklık katsayısı ve çarpıklık katsayısı değerleri alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük hamsi kokusu örüntüsü	140
Şekil 3.104.	Öznelik olarak ortalama değeri, standart sapma, basıklık katsayısı ve çarpıklık katsayısı değerleri alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük mezgıt kokusu örüntüsü	141
Şekil 3.105.	Öznelik olarak zaman parametreleri(yükselme zamanı, vb.) alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük istavrit kokusu örüntüsü	141
Şekil 3.106.	Öznelik olarak zaman parametreleri(yükselme zamanı, vb.) alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük hamsi kokusu örüntüsü.....	142
Şekil 3.107.	Öznelik olarak zaman parametreleri(yükselme zamanı, vb.) alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük mezgıt kokusu örüntüsü	142

Şekil 3.108. Öznitelik olarak, 6 parçaya ayrılmış sensör cevaplarının türevi alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük istavrit kokusu örüntüsü	143
Şekil 3.109. Öznitelik olarak, 6 parçaya ayrılmış sensör cevaplarının türevi alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük hamsi kokusu örüntüsü.....	143
Şekil 3.110. Öznitelik olarak, 6 parçaya ayrılmış sensör cevaplarının türevi alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük mezgit kokusu örüntüsü	144
Şekil 3.111. Öznitelik olarak alt örnekleme uygulandığında a) TGS 880-825 b) TGS 830-826 c) TGS 2610-2620 d) TGS 2602-2104 sensörleri için 3 günlük istavrit kokusu örüntüsü	144
Şekil 3.112. Öznitelik olarak alt örnekleme uygulandığında a) TGS 880-825 b) TGS 830-826 c) TGS 2610-2620 d) TGS 2602-2104 sensörleri için 3 günlük hamsi kokusu örüntüsü.....	145
Şekil 3.113. Öznitelik olarak alt örnekleme uygulandığında a) TGS 880-825 b) TGS 830-826 c) TGS 2610-2620 d) TGS 2602-2104 sensörleri için 3 günlük mezgit kokusu örüntüsü	146

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. E-burun uygulamalarında kullanılan sensörler [1].	8
Tablo 1.2. E-burunda literatürde kullanılan sınıflandırma yöntemleri [1].	24
Tablo 2.1. Koku iletim sistemi elemanları ve teknik özellikleri	32
Tablo 2.2. Figaro gaz sensörlerinin teknik özellikleri	38
Tablo 2.3. Gaz sensörleri, hedef gazları ve yük dirençleri	38
Tablo 2.4. Veri elde etme kartı giriş çıkış işaret tanımları	42
Tablo 2.5. E-burun ile koku alıp verme döngüsü	44
Tablo 2.6. Birincil kokuların oluşturduğu veri tabanı	46
Tablo 2.7. Balık tazeliği testi için kullanılan veri tabanının günlere göre veri dağılımı.	47
Tablo 2.8. VERİ4 için eğitim ve test verilerinin dağılımı	48
Tablo 2.9. Veri tabanları veri dağılımı	49
Tablo 2.10. Örnek sensör işareti için bölgeler	52
Tablo 2.11. Kullanılan parametre çıkarma yöntemleri	53
Tablo 2.12. Farklı veri tabanlarında alt örnekleme öznelik çıkarma yöntemi parametreleri.	56
Tablo 2.13. VERİ1 için sınıf ve ikili karar ağacı bilgileri	69
Tablo 2.14. VERİ2 için sınıf ve ikili karar ağacı bilgileri	72
Tablo 2.15. VERİ3 için sınıf ve ikili karar ağacı bilgileri	73
Tablo 2.16. VERİ4 için sınıf ve ikili karar ağacı bilgileri	74
Tablo 2.17. Karışıklık matrisi	75
Tablo 3.1. VERİ2 için farklı özneliklerle sınıflandırma sonuçları	129
Tablo 3.2. VERİ3 için farklı özneliklerle sınıflandırma sonuçları	137
Tablo 3.3. VERİ4 için farklı özneliklerle sınıflandırma sonuçları	147
Tablo 3.4. VERİ1 için farklı algoritmalarla sınıflandırma sonuçları	148
Tablo 3.5. VERİ1 için önerilen ikili karar ağacı yapısında kullanılan sınıflandırıcılar, sınıflandırıcı parametreleri ve seçilen öznelikler	149
Tablo 3.6. VERİ1’de numaralandırılan sınıflara ait konsantrasyon değerleri	150
Tablo 3.7. VERİ1 için önerilen sınıflandırma modeli uygulandığında elde edilen karışıklık matrisi	151
Tablo 3.8. VERİ2 için farklı algoritmalarla sınıflandırma sonuçları	152

Tablo 3.9.	VERİ2 için önerilen ikili karar ağacı yapısında kullanılan sınıflandırıcılar, sınıflandırıcı parametreleri ve seçilen öznitelikler	153
Tablo 3.10.	VERİ2 için önerilen yöntem kullanılarak elde edilen eğitim verisine ait karışıklık matrisi.....	153
Tablo 3.11.	VERİ2 için önerilen yöntem kullanıldığında test verisine ait karışıklık matrisi.....	154
Tablo 3.12.	VERİ3 için farklı algoritmalarla sınıflandırma sonuçları	155
Tablo 3.13.	VERİ3 için önerilen ikili karar ağacı yapısında kullanılan sınıflandırıcılar, sınıflandırıcı parametreleri ve seçilen öznitelikler	155
Tablo 3.14.	VERİ3 için önerilen yöntem kullanılarak eğitim verisine ait karışıklık matrisi.....	156
Tablo 3.15.	VERİ3 için önerilen yöntem kullanılarak test verisine ait karışıklık matrisi.....	156
Tablo 3.16.	Önerilen yöntem ve literatürdeki yöntemlerin karşılaştırılması.....	157
Tablo 3.17.	VERİ4 için farklı algoritmalarla sınıflandırma sonuçları	158
Tablo 3.18.	VERİ4 için önerilen ikili karar ağacı yapısında kullanılan sınıflandırıcılar, sınıflandırıcı parametreleri ve seçilen öznitelikler	158
Tablo 3.19.	VERİ4 eğitim verisi için önerilen yönteme ait karışıklık matrisi	159
Tablo 3.20.	VERİ4 test verisi için önerilen yönteme ait karışıklık matrisi	159

SEMBOLLER DİZİNİ

ÇBÖ	: Çok Boyutlu Örnekleme
MDS	: Multidimensional Scaling
MOS	: Metal Oksit Yarı İletken (Metal Oxide Semiconductor)
Pd	: Paladyum
Pt	: Platin
ZnO	: Çinko Oksit
WO ₃	: Tungsten
TiO ₂	: Titanyum Oksit
SiO ₂	: Silisyum Oksit
MOSFET	: Metal Oksit Yarıiletken Alan Etkili Transistör (Metal Oxide Semiconductor Field Effect Transistor)
TIRF	: Toplam İç Yansıma Işıma (Total Internal Reflection Florescence)
FOED	: Fiber Optik Evanesans Dalga
KSD	: Kütle Ses Dalgası
YSD	: Yüzey Ses Dalgası
BPD	: Bükülgen Plaka Dalgası
KS	: Karakter Sayısı
QCM	: Kuvartz Kristal Mikrobalans (Quartz Crystal Microbalance)
IDT	: Inter Dijital Transduserleri
IIR	: Sonsuz Darbe Tepkisi (Infinite Impulse Response)
FIR	: Sonlu Darbe Tepkisi (Finite Impulse Response)
TBA	: Temel Bileşen Analizi
DAA	: Doğrusal Ayırıştırma Analizi
BAA	: Bağımsız Bileşen Analizi
GA	: Genetik Algoritma
AİS	: Ardışıl İleri Seçme
AGS	: Ardışıl Geri Seçme
SA	: Sınır Ağları
KEKKY	: Kısmi En Küçük Kareler Yöntemi
ÇDR	: Çoklu Doğrusal Regresyon

TBR	: Temel Bileşen Regresyonu
AFA	: Ayrık Fonksiyon Analizi
CA	: Kümeleme Analizi (Cluster Analysis)
ÇKA	: Çok Katmanlı Algılayıcı
ÖDH	: Öz Düzenleyici Haritalar
RTF	: Radyal Tabanlı Fonksiyon
OSA	: Olasılıksal Sinir Ağları
VKÖ	: Vektör Kuantalamalı Öğrenme
BÇS	: Bulanık Çıkarım Sistemi
BSA	: Bulanık Sinir Ağları
BCO	: Bulanık C Ortalamaları
URT	: Uyarlamalı Rezonans Teorisi
DVM	: Destek Vektör Makinası
k-EYK	: k-En Yakın Komşuluk
KAK	: Kütle Akış Kontrolör
DAQ	: Veri Elde Etme (Data Acquisition)
R	: Referans Seviye
KA	: Koku Alma
SD	: Sürekli Durum
KV	: Koku Verme
VERİ1	: 1. Veri Tabanı
VERİ2	: 2. Veri Tabanı
VERİ3	: 3. Veri Tabanı
VERİ4	: 4. Veri Tabanı
SR	: Sensör Referansı
YK	: Yükselen Kenar
DK	: Düşen Kenar
DP	: Doğru Pozitif
DN	: Doğru Negatif
YP	: Yanlış Pozitif
YN	: Yanlış Negatif

1. GENEL BİLGİLER

1.1. Giriş

Günümüzde birçok alanda kullanılan kimyasal görüntüleme kimyasal örnekleri kaydetmeyi sağlar. Analitik kimya yöntemi olarak bilinen gaz kromatografi ile kimyasal görüntüleme elde edilirken, bir diğer yöntem de sensörlerle kimyasal bileşenleri ortaya çıkarmaktır. Bu da elektronik burun (e-burun) olarak adlandırılır. Genel bir tanımı yapılacak olursa; e-burun insanların koku alma organından esinlenerek geliştirilmiş algılayıcı birimile kokuları ve uçucu bileşenleri algılayıp, yapay zeka ve örüntü tanıma alt sistemlerini yapısında bulunduran cihazlardır [1].

E-burun ile sadece koku moleküllerinin nelerden oluştuğu algılanmamakta, ayrıca kokuda bulunan bu moleküllerin yoğunlukları da algılanmaktadır [2]. Yapılan çalışmalar göstermektedir ki, insan burnundan esinlenerek yapılan bu cihazlar, biyolojik yapısı tam anlaşılammış insan koku algılama sisteminin mükemmel yapısına henüz ulaşamamıştır. Aslında bunun sebeplerinden biri biyolojik koku alma sisteminin yapısının hala tam olarak anlaşılammamasından kaynaklanmaktadır.

Diğer gaz analiz cihazlarına göre kullanımı oldukça kolay olan e-burunların günümüzde birçok uygulamada yer almasının önü bu alanda yapılan çalışmalarla açılmıştır. E-burunlar başlıca yiyecek ve içecek endüstrisinde, otomotiv ve uzay uygulamalarında, parfüm ve koku endüstrisinde, tıbbi teşhiste ve çevresel takipte kullanılmaktadır.

En yaygın kullanıldığı yiyecek ve içecek endüstrisinde önemli çalışmalar yapılmış ve ticari ürün haline getirilmiştir. Çay üretiminin mayalanma aşamasında biyolojik burun kullanılırken yavaş yavaş bunların yerini e-burun almaktadır [3-6]. Yine şarap kokusundan, farklı içeceklerden kalite ayırımı yapmak veya sebze, meyve, et ürünlerinin tazeliğini belirlemek amacıyla sıklıkla kullanılmaktadır [7-14]. Ayrıca yiyeceklerde oluşan yararlı ve zararlı bakterileri algılamada da kullanılmaktadır [15,16].

Arabalarda yanma gazlarının verimini, otomobil iç havasının yolcular için kalitesini, sızan yakıt olup olmadığını gözlemlemek için kullanılmaktadır [17,18]. Uzay uygulamalarında ise gezegen atmosferleri ilgili çalışmalarda veya kabin içi havanın kalitesini ve nefes alınabilirliğini belirlemek amacıyla kullanılmaktadır [19-22].

Kozmetik ve koku endüstrisinde birçok problemi aşmada e-burun kullanılmaktadır. Parfüm kokularının ve aromalarının ayırt edilmesiyle ilgili birçok çalışma yapılmıştır [23-25].

Çevresel takipte ise çiftlik uygulamaları, hava kirliliği, zehirli gazlar gibi çeşitli uygulamalara rastlanmaktadır [26-29]. Özellikle hayvan çiftliklerinde oluşan gazları tespit etmek amacıyla sıklıkla kullanılmaktadır [30-32].

Bunlara ek olarak e-burun değişik uygulamalarda da yer almaktadır. Mobil e-burun gerçekleştirerek kokunun kaynağını bulmayı sağlayan robotlar yapılmıştır [33,34]. Robotlar için biyotik e-burun tasarlanmış [35], kirli çamaşırları algılayıp ona göre yıkama programı seçen e-burunlar çamaşır makinelerine entegre edilmiştir [36]. Bunlara ilaveten algıladığı kokuyu yeniden üreten cihazlar üzerinde araştırmalar yapılmakta, hatta bunlar internet ve televizyon teknolojilerine entegre edilmeye çalışılmaktadır [37,48]. Ayrıca tarım endüstrisinde tarım zararlılarının algılanmasında da karşımıza çıkmaktadır [39,40]. Biyometrik tanıma uygulamalarına örnek olarak insanları kokusundan ayırt etme çalışmaları yapılmıştır ve geliştirilmeye açık bir konudur [41-43].

Bu örnekler farklı uygulamalar için çoğaltılabilir. E-burunun tıbbi uygulamalardaki önemi ise gün geçtikçe artmaktadır. İnsan vücudunun ürettiği kan, ter, idrar ve nefes gibi parametreler hastalık tanıları için bilgi içermektedir [44,2]. Bu parametrelerin kokularından yararlanarak sindirim sistemi problemleri, karaciğer problemleri, enfeksiyonlar, şeker hastalığı gibi hastalıkların tanısı konulabilmektedir. South Manchester Üniversite hastanesinde yara enfeksiyonunun kokudan anlaşılması üzerine çalışmalar yapılmaktadır [45]. Özellikle akciğer kanseri tanısı konmasında çalışmalar sürmektedir [46-50]. Diğer hastalıklardan göğüs kanseri [47,51], idrar yolu enfeksiyonları [52-56], kulak burun boğaz ve göz enfeksiyonları ile bakterilerinde [57-60], böbrek hastalıkları [61], şizofren ve depresyon hastalıkları [62-64], şeker hastalığı [65-67], insan papila virüsü [68], kalp hastalığı [67] ve karaciğer hastalığı [69] üzerinde çalışmalar yapılmaktadır. Bu çalışmalara ilaveten, e-burun cesetlerin ölüm saatlerinin tespitinde adli tıp çalışmalarında da kullanılabilir.


Çok yaygın kullanım alanına sahip olan e- burunun ticari olarak daha yaygın hale gelmesi ve daha başarılı sonuçlar üretmesi için çalışmalar hızla devam etmektedir. Bu çalışmada da e-burunda meydana gelen sorunları dikkate alarak, farklı veri tabanları için daha başarılı sonuçların elde edileceği sayısal işaret işleme algoritmaları geliştirilmiş ve kullanılmakta olan algoritmalarla kıyaslanmıştır.

E-burun genel olarak 4 birimde incelenebilir. Bunlar algılayıcı birim, dönüştürücü birim, elektronik birim ve örüntü tanıma birimidir. Bu çalışmada her birimin görevine, sorunlarına değinilmiş ve bu sorunlara çözümler sunulmuştur.

Genel bilgiler kısmında; e-burun koku örüntülerini ayırt etmek üzere kullanıldığından, öncelikli olarak koku uzayı incelendi. Daha sonraki bölümlerde e-burunun temel alındığı biyolojik burun, e-burunun birimleri ve sorunları detaylı olarak incelenmiştir.

1.2. Koku Uzayı

Linnaeus 1752'de kokuları aromatik, ıtırılı (fragrant), nefis kokular (ambrosial), sarımsak-soğan kokuları (alliacous), keçi kokuları (hircine), iğrenç kokular (repulsive) ve mide bulandırıcı kokular (nauseous) olmak üzere 7 gruba ayırdı [70]. Henning ise 1916'da birincil kokuları tanımlamaya çalıştı [71]. Kokuları tanımlamada kullanmak üzere köşelerinde çürük kokular (putrid), ıtırılı kokular, baharatlı kokular (spicy), çamsakızı kokular (resinous), yanık kokular (burned) ve çok hafif kokulardan (ethereal) oluşan Şekil 1.1'deki 6 köşeli prizmayı önerdi. Örneğin kekik kokusunun ıtırılı koku ile baharatlı koku arasında bir yerde olması gerektiğinden yola çıkıp kokuları prizmada yerleştirmeye çalıştı. Ama tüm kokular bu koku prizmasının içerisine dahil olmadığından bu yöntem tercih edilmedi. 1968'de Woskow, verilerin metrik olduğu varsayımı altında psiko-fiziksel veriyle çok boyutlu ölçekleme (ÇBÖ,(Multi Dimensional Scaling-MDS)) yöntemini kullandı [72]. Shiffman, Woskow'un önerdiği ÇBÖ'yi metrik olmayan verilerle yeniden analiz etti [73]. Analizinde kokunun niteliğini tahmin etmede tek bir psiko-kimyasal parametrenin kullanılamayacağı sonucuna vardı. Bu psiko-kimyasal haritalara ek olarak parfüm endüstrisinde çeşitli deneysel yaklaşımlar kullanıldı.



Şekil 1.1. Henning piramidi [71].


Bunların yanısıra kokuların 7 temel bileşenden oluştuğunu gösteren çalışmalar da vardır. Bu birincil 7 kokuyu; hafif kokular (etharal), kafur (camphoraceous), misk (musky), çiçek (floral), naneli (minty) ve çürük (putrid) kokuları oluşturmaktadır [74]. Tez çalışmasında ilk oluşturulan veri tabanı, bu birincil kokulara örnek teşkil eden kokulardan oluşturulmuştur. 2000’de Chee-Ruiter’in önerdiği graf, koku özellik uzayını göstermektedir [75]. Bu koku uzayı, kokunun yönlü grafi kullanılarak oluşturuldu. A kokusu, B kokusuyla aşağıda verilen benzerlik miktarınca bağlantılıdır.

$$I = P(A|B).P(B|A) \quad (1.1)$$

(1) denkleminde I , A ile B kokusu arasındaki yakınlığın ölçüm bilgisidir [70]. Halen tabiatta kaç çeşit koku olduğu bilinmemektedir. Kokuya karakteristik niteliğini moleküller arası meydana gelen mikroskobik değişiklikler verir. Koku moleküllerindeki tek bir atom değişikliği bile, güzel gelen kokunun itici hissedilmesine sebep olabilir. Birçok koku molekülünden meydana gelen kokuyu tek bir koku gibi algılarız. Örnek olarak siyah çay 550’den fazla koku molekülünden oluşur [76]. Sıcaklık artışı moleküllerin hızlarının artmasına ve daha çok koku molekülünün havada serbest dolaşımına neden olur. Bu şekilde insan burnu kokuyu çok daha çabuk algılar. İnsan burnu yaklaşık olarak 10000 kokuyu ayırt edebilir [77]. E-burunun esinlendiği insan burnunun, koku uzayındaki bu kokuları nasıl algıladığını daha iyi anlamak için biyolojik koku algılama sisteminin genel yapısını incelemek gerekmektedir.


1.3. Biyolojik Koku Algılama Sistemi

Biyolojik koku algılama organı; karada yaşayan canlılarda, özellikle besinini ve avını koklayarak bulmak zorunda olan canlılarda ileri seviyededir. Burun boşluğunun üst tarafındaki mukoza içeren bölge olan *regio olfactoria*, koku algılama hücresi denilen *olfaktör reseptörler* içermektedir [78]. Koku algılama hücresi 3 ana bölümden oluşmaktadır. Hücre gövdesi, tüycükler (silya) ve akson uzantısı Şekil 1.2’de gösterildiği gibidir.



Şekil 1.2. Koku algılama hücresinin genel yapısı [78].

Hücre, gövdesi pek çok karmaşık hücresel işlemin gerçekleştiği; akson, elektrik işaretinin taşındığı; tüycükler de koku molekülleri ile temasın kurulduğu bölgelerdir. Biyolojik koku algılama hücreleri dış dünya ile direkt ilişkide olup beyinle doğrudan iletişim kurarlar. Koku almak için suda ya da yağda eriyebilen bileşiklerin burun mukozasına teması gerekir. Etkin bir koku uyarımı için burunda hava akımı gerekmektedir. Koku duyusunun ilk basamağı burundaki koku duyu sinirlerinde başlar. Olfaktör reseptör diye adlandırılan koku algılama hücreleri, nazal mukozanın özelleşmiş bölümü olan, olfaktör mukoz membranda yerleşmişlerdir. Bu alanın genişliği ile koku duyarlılığı doğru orantılıdır. İnsanda 10 ila 25 milyon arasında değişen sayıda reseptör hücresi bulunmaktadır. Olfaktör reseptörler algıladıkları kokuyu sinir impulslarını çevirerek olfaktör bulbus (yumrular) sayesinde olfaktör yolla serebral korteksin temporal lobunda yer alan primer olfaktör kortekse ulaştırır [78]. Burada açıklanan koku algılama sistemi Şekil 1.3’de gösterilmektedir.

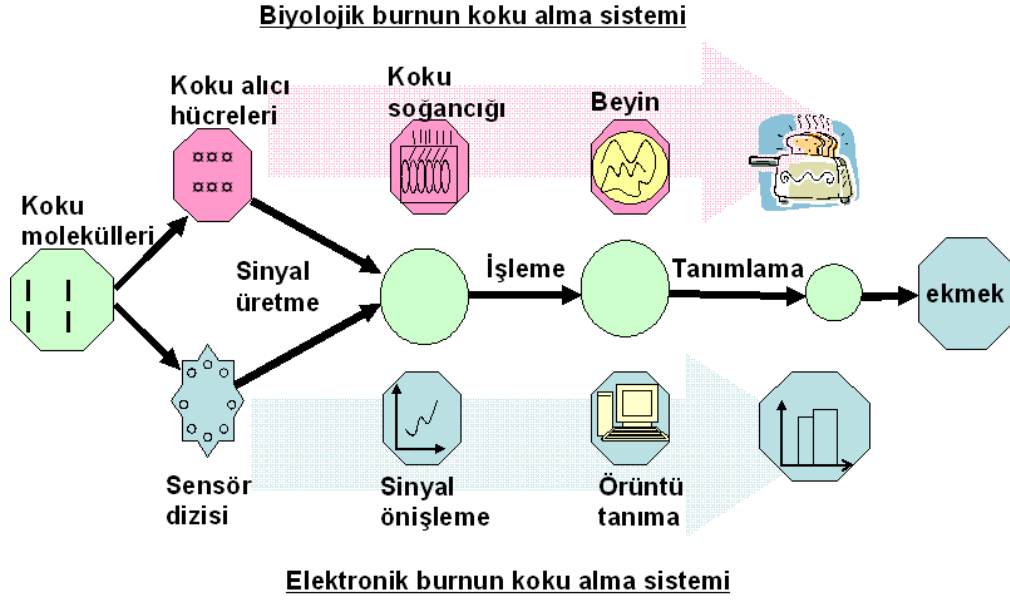


Şekil 1.3. Koku algılama sistemi [79].

Koku algılama mekanizması genel yapı ile bilinse de, koku sinir hücrelerinin tüylü uçlarının koku moleküllerini nasıl yakaladıkları veya algıladıkları bilinmemektedir. Bir kısım bilim adamının görüşlerine göre her koku molekülü kendine has frekansta titreşim yayarak burnumuzdaki koku sinirlerinin bu titreşimi algılamasını sağlamaktadır. Aynı görüşe göre koku molekülleri seste olduğu gibi dalgalar halinde yayıldığından sinir hücreleri ile moleküller arasında doğrudan bir temas gerekmiyor [79]. Bir başka görüşe göre ise, her koku molekülünü algılayan koku duyusu sinirleri özelleşmiştir. Koku bilgisi sinirler aracılığıyla beyindeki koku merkezine ulaştığında beyin daha önceki deneyimlerle belirlenmiş olan şifreleri çözerek kokunun tanınmasını sağlar [1]. Başka bir görüş ise, kokunun renklere benzediğini savunur. Böylece tıpkı renkleri oluşturan ana renkler gibi, tüm kokuları oluşturan ana birincil kokular olduğu ileri sürülmektedir [70]. İlerleyen yıllarda bu kısımdaki belirsizliklerin giderilmesiyle, belki de daha üst düzey sensörler e-burunlarda kullanılacak ve daha gelişmiş e-burunlar üretilecektir.

1.4. Elektronik Burun

E-burun biyolojik burunun üstün özelliklerine ulaşmasa da üstün olduğu tarafları da vardır. İnsan burnu kokuyu algılamada subjektif davranırken, e-burun ise objektif davranır. Ayrıca insan burnu bazı zehirli gazları algılayamamaktadır veya bir süre sonra kokuya duyarlılığı azalır yok olmaktadır [2]. Bu ve benzeri nedenlerden dolayı e-burun çalışmaları hız kazanmıştır. E-burun, algılama birimi, dönüştürücü birim, elektronik birim ve örüntü tanıma birimi olmak üzere 4 önemli kısımdan meydana gelmiştir. E-burunun kısımlarının biyolojik burunun hangi kısımlarından etkilendiği Şekil 1.4'de görülmektedir.



Şekil 1.4. Elektronik burun biyolojik burun ilişkisi [1].

Algılayıcı birim ortamdaki koku molekülleriyle etkileşerek kullanılan sensöre göre işaret oluşturur. Dönüştürücü birimde ise kullanılan sensöre göre sensördeki değişimi yansıtan elektriksel işaret üretilir. Elektronik birim; dönüştürücülerin elektrik işareti üretmesi için gereken osilatör devresi, filtre devresi, fark devresi gibi devrelerden oluşmaktadır. Örüntü tanıma birimi ise algılanan ön işlemden geçmiş işaretin sınıflandırılması ve tanınması görevini üstlenir.

Her sensör koku hakkında öznel bilgileri verir. Bu sistem, alınan birçok öznel bilgiye bağımsız öznel bilgileri belirler ve bunları optimize etmeye çalışarak kimyasal bilgiyi elde etmeye çalışır. Bölüm 1.4’de sırasıyla e-burun birimleri incelenmektedir.

1.4.1. Algılayıcı Birim

Algılayıcı biriminin temel elemanı olan kimyasal sensörler kimyasal bilgiyi elektriksel işarete çeviren algılayıcılardır. Tablo 1.1’de literatürde kullanılan sensörler gruplandırılarak verilmiştir [1]. Bundan sonraki bölümlerde bu gruplardaki sensörlerin çalışma prensiplerine genel olarak değinilmiştir.

Tablo 1.1. E-burun uygulamalarında kullanılan sensörler [1].

Prensip	Ölçülen Büyüklük	Sensör Tipleri	Avantaj	Dezavantajı
Elektro-kimyasal	İletkenlik	MOS	Ucuz olması	Yüksek sıcaklıkta çalışması
		CP CO	Oda sıcaklığında çalışması	Neme karşı çok hassas
	Akım-Gerilim	MOSFET	CMOS tabanlı kimyasal sensörlere uygulanabilmesi ve entegre edilebilmesi	Geç tepkime cevabı
	Kapasite	Polimer	CMOS tabanlı kimyasal sensörlere uygulanabilir	Neme karşı çok hassas
	Gerilim	Şotki diyot	CMOS tabanlı kimyasal sensörlere uygulanabilmesi ve entegre edilebilmesi	Platin, Altın, İridyum gibi pahalı maddelere gereksinim duyması
	Akım	Elektro-katalitik	Elektriksel gürültüden etkilenmeme	Boyutu
Isıl	Sıcaklık	Pelistör Termokupl Termistör	Düşük maliyetli olması	Geç tepkime cevabı
Optik	Işığın kırılması	SPR	Anlaşılabilir teknolojiye sahip olması	Pahalı
	Yoğunluk	Floresans	Yüksek hassasiyete sahip	Sınırlı ışık kaynağı
Gravimetrik	Piezo-Elektrik	QCM (BAW) SAW FW	Düşük maliyetli olması	Arayüz elektroniği

1.4.1.1. Elektro-Kimyasal Sensörler

E-burun sensörlerinden uygulamada en sık kullanılan ve bu tezde kullanılmakta olan kimyasal dirençlerin farklı türleri vardır. Bunlardan en yaygın kullanılanları, metal oksit yarı iletkenler, iletken polimerler ve iletken oligamerlerdir. Genel olarak yapıları incelendiğinde gazla temasında sensörlerin dirençlerinin değiştiği gözlenmektedir.

Metal Oksit Yarı iletken (Metal Oxide Semiconductor, MOS) gaz algılamada kullanılması ilk defa 1962 yılında gerçekleşmiştir. İlk ticari MOS sensörler ise 1968

yılında Taguchi tarafından üretilmiştir. Bu sensörler e-burun uygulamalarında en çok kullanılan sensörlerdir. Taguchi ticari sensörleri ısıtma bobini monte edilmiş seramik silindirden oluşur. Dış yüzeyi az miktarda Paladyum (Pd) veya Platin (Pt) ile karıştırılmış metal oksit genelde kalay oksit tabakası ile kaplıdır. Metal oksit olarak; çinko oksit (ZnO), tungsten oksit (WO_3) veya titanyum oksit de (TiO_2) kullanılmaktadır. Gaz molekülleri sensörün yüzeyine temas ettiğinde gerçekleşen redoks tepkimeleri ile MOS'un direncinde değişim meydana gelir. Bu reaksiyonlara yükseltgenme veya indirgenme denir. Elektron alışverişine dayanmaktadır. İndirgenme evresinde havadaki oksijen emilir ve yarı iletkenin iletken bandı tarafından yakalanan serbest elektronlar sensörün direncinin artmasına sebep olur. Yükseltgenme evresinde emilen oksijen sensöre temas eden gaz molekülü ile tepkimeye girer ve bunun sonucunda yüzeydeki oksijen yoğunluğu azalır. Böylece yakalanan elektron etkisi azalır ve elektronların iletken banda yeniden dönmesine sebep olur. Etki eden gaz molekülüne göre sensörün direncinin değişmesine neden olur. MOS genellikle 300-500° C sıcaklıkta çalışır. 5 ile 500 ppm arasında hassasiyete sahiptir. Taguchi sensörlerinin yüksek sıcaklıkta çalışması gerektiğinden yüksek güç harcarlar.

Bir diğer kimyasal direnç tipi olan polimerler, en basit tanımıyla çok sayıda aynı veya farklı grupların kimyasal bağlarla, az veya çok düzenli bir biçimde bağlanarak oluşturduğu uzun zincirli, başka bir ifade ile yüksek molekül ağırlıklı bileşiklerdir. İlk ticari e-burunlarda kullanılan iletken polimerlerin gazlara doğal cevapları bilinmemekle beraber birçok teori ileri sürülmektedir. İletken polimerler kimyasal direnç olarak kullanıldığında, iletken polimerin iletkenliği indirgenir ve oksitlenebilir bir gazla temas ettiğinde değişir. Organik iletken polimerler, kimyasal maddeler(etil alkol, metil alkol, etil asetat) polimerden emildiğinde veya ayrıştırıldığında iletkenliğinde tersinir etki gösterir. 0.1-100 ppm hassasiyetinde ortam sıcaklığında çalışabilmektedir. En büyük dezavantajları nemden etkilenmeleri ve zamanla oksitlenmeye uğramalarıdır. İletken polimerler genelde algılamada kimyasal direnç olarak kullanılmaktadır. Ama MOS alan etkili transistörlerde (MOSFET) ve piezo elektrik kristallerde de uygulamasına rastlanmaktadır. Gaz algılamada en çok kullanılan polimerler polipirol, polianilin, politiyofen, poliasetilendir.

Gaza hassasiyeti olan Pd kapılı MOSFET'in ilk olarak gaz algılamada kullanımı 1975'e dayanmaktadır [80]. MOSFET sensörün yalıtımı oksitle yapılıyorsa genelde kalay oksit (SiO_2) kullanılır.

MOSFET'te metal gate ucuna potansiyel uygulandığında, yarı iletken-yalıtkan sınırında bir kanal meydana gelir. Bu da source'dan drain'e akım akmasını sağlar.

Bu sensörde herhangi bir gaz reaksiyonu metal gate ucunda deęişikliğe veya yalıtkan özelliklerinde deęişime yol açacağından dolayı MOSFET sensörünün elektrik özelliklerinde deęişim meydana gelir. Böylece sensör cevabı için, MOSFET'te deęişen drain akımını sabit tutmak için gerekli gate gerilim deęişimi ölçülür.

Akıma dayalı sensörler genelde altın veya platinyum kullanılan elektrotların gazla temaslarında sabit gerilim altında akıttığı akımın ölçülmesi ilkesine dayanır. İlk yapılan e-burunlarda bu tip gaz sensörleri kullanılmıştır [1]. Akıma dayalı sensörler uygulamada SO₂, NO ve CO₂ gazlarının algılanmasında kullanılmıştır [81]. Amperometrik sistemlerde akım, elektrokimyasal reaksiyon hızının bir göstergesidir. Amperometrik sensörlerde etki eden gazın ppm seviyesi olması durumunda, akımda mikro veya piko amperler seviyesinde deęişim olur. Amperometrik sensörlerin en büyük avantajı yüksek hassasiyette, düşük maliyetli olmaları ve kullanım ömürlerinin uzun olmasıdır.

1.4.1.2. Isıl Sensörler

Isıl sensörler pelistör, katalitik çubuk veya yanıcı gaz sensörleri diye adlandırılır. Katalitik sensörler katalizör çubuğun ince sargılarla sarılmasından elde edilir. Platin kablolar platin rezistif termometre gibi davranır. 500° C'ye kadar ısıtıldığında hidrokarbonla herhangi bir temasında katalitik oksidasyona neden olur. Katalizörün ısıtılmasıyla ısının bir kısmı katalitik yüzeyinde ve çevrede kaybolur. Transfer edilen ısı sensörün sıcaklığının yükselmesine neden olur, buda Pt kablunun direncinin deęişimine neden olur. Sensör devresi de genellikle Wheatstone köprü devresine yerleştirilerek Pt kabloda meydana gelen deęişiklikler ölçülür. Bu sensörler genellikle yanıcı gazların algılanmasında kullanılır [1].

1.4.1.3. Optik Sensörler

Optik gaz sensörleri yapay burunlarda sıkça kullanılmaktadır. Burada ışık kaynağı algılanan gazla referans molekülü tahrik eder. Ölçülen işaret; emilim, yansıtma veya ışımaya özelliklerindeki optik deęişimlerdir. Optik sensörler dalgaboyu bilgisi ve yoğunluğu eş zamanlı toplayabilmesinde olduğu gibi çok amaçlıdır ve birkaç tekniği kapsamaktadır. Bunlardan en bilinenleri floresans sensörleri, yansıtıcı sensörler ve emilim sensörlerdir.

Floresans sensörler, ışım tekniklerinde genellikle optik fiberlerden faydalanılır. Çoğu kimyasal sensör uygulamaları fiberleri, ışık kaynağının sensör elemanına bağlantısı için kullanır [82]. Toplam iç yansıma ışması (TİYI, Total Internal Reflection Florecance-TIRF) ve fiber optik evanesans dalga (FOED) sensörleri evanesans çıkışına bağlıdır. Bu fiberin kılıflı ama giydirilmemiş daire duvarında yer alır. Uzak uç ise algılayıcıya meydana gelen ışığı iletir.

İlk optik e-burun tasarımında polimer boya ile kaplanmış fiber optik kullanılmıştır [83]. Farklı polimer/boya değişimleri algılama özelliklerinde farklılıklara yol açmaktadır. Alternatif yöntem olarak da farklı boya ve polimerler kullanılabilir. Optik sensör dizisi oluşturmanın iki yöntemi vardır. Bunlardan ilki birçok bir arada fiberin ve yüzey üzerinde foto polimerleşmiş sensör bölgelerinin kaynaşmasına dayanmaktadır [84]. İkinci yöntem ise fiberin uzak yüzeyi üzerine yerleştirilmiş algılama çubuklarında kimyasal aşındırmayı içermektedir [85].

Yansıtıcı sensörlere örnek olarak, Leipter [86] gaz algılamak için reflektometrik girişim spektroskop yöntemini kullanmıştır. Bu sistem beyaz ışık interferometrisini polimer algılama tabakasındaki ince değişiklikleri ölçmek için kullanmasına dayanır. Bu hassas değişiklikler, gaz moleküllerinin bu tabakaya temasıyla meydana gelir. Farklı algılama tabakaları kullanarak bu sistem sensör dizisi haline getirilebilir.

Emilim sensörlerden olan porfirin tabanlı sensör dizilerine ilgi son yıllarda artmıştır. Porfirin halka sistemleri geçiş metal iyonları ile yüksek kararlı şekilde karmaşık biçimlenebilir ve Soret bandında emilim ile yüksek kromojen davranışlar sergiler. Metal-porfirin gaz molekülleri ile temasında soğurma tayfında değişiklik meydana gelir.

1.4.1.4. Gravimetrik Sensörler

Curie kardeşler 1880'de [87], kuvars üzerine uygulanan basıncın deforme olmuş iki yüzey arasında bir elektrik alanın oluşmasına sebep olduğunu gözlemlediler. Bunun karşıtı olarak iki yüzey arasında yapılan elektrik alan uygulaması da yüzeylerde kesin bir bozulmaya neden olmaktadır. Bu etkiden yararlanarak gaz algılanmasını sağlayan sensör çeşitleri Kütle ses dalgası (KSD),Yüzey ses dalgası (YSD) ve Bükülgen Plaka Dalgası Sensörler (BPD) sensörlerdir.

KSD sensörleri çoğunlukla Kalınlık Makaslama Modu sensörleri veya Kuvartz Kristal Mikrobalsan (KKM) sensörleri diye adlandırılırlar. Algılamanın temeli kristalde biriktirilmiş malzemenin kütlesiyle orantılı olarak kristalin frekansındaki değişimdir.

Standart bir KSD sensör için 1 Hz'lik değişim 1 ng kütle değişiminde meydana gelir. YSD bir sıvının veya katının yüzeyinde ilerleyen dalgaya denir. Piezoelektrik kristalin bir yüzeyine yerleştirilen ve dişleri birbiri içine gelecek şekilde karşılıklı konulmuş tarağa benzeyen elektrot sistemi ile uyarılırlar. Piezoelektrik etki elektriksel giriş işaretinden YSD üretmeye ya da YSD'den elektriksel işaret elde etmeyi sağlar. Elektrik alan mekanik gerilim ve uzama oluşturur, mekanik gerilimde basınç meydana getirir. YSD sensörlerinin ince bir filmle kaplanması ve kaplananan tabaka üzerinde meydana gelen gaz absorbesinden kaynaklanan kütle değişimleri Rayleigh dalga hızının önemli miktarda azalmasının yanı sıra paralel olarak aygıtın rezonans frekansında da bir azalmaya neden olmaktadır. Genellikle gaz algılama uygulamalarında titreşim frekansındaki kayma göz önüne alınmaktadır [88].

BPD veya diğer bir adıyla Lamb dalga cihazı 1988'de Wenzel ve White tarafından geliştirilmiştir [89]. Bu cihaz bükülgen karakter gösteren simetrik olmayan Lamb dalgalarını kullanır. YSD'ye benzer olarak; BPD polimer kaplanmış geciktirme hattı ile ayrılmış Inter Dijital Transduserleri (IDT) kullanır. Bununla birlikte bir BPD sensörde Lamb dalgaları Lamb dalga boyundan daha küçük kalınlıkta olan akustik tabaka üzerinden yayılır. Malzemeye genellikle çinko oksit gibi piezoelektrik tabaka ile silikon püskürtülür. BPD sensörlerde kullanılan devrenin daha az karmaşık olmasına ve daha düşük frekansların kullanımına, daha az gürültü seviyesine ve daha az yoğunlukta gazın algılanmasına imkan sağlar.

1.4.2. Dönüştürücü Birim

Sensörlerden alınan bilgiyi elektriksel işarete çevirmeyi sağlayan birime dönüştürücü birim denir. Kullanılan sensörün çeşidine göre arayüz devreleri çeşitlilik göstermektedirler.

E-burun uygulamalarında sıklıkla kullanılan kimyasal dirençlerin ürettikleri işaretleri elektrik işarete dönüştürmek için literatürde çeşitli yöntemler kullanılmıştır. Bunlar içinden en sık kullanılanları gerilim bölücü, Wheatstone köprüsü veya alternatif akım (AC) empedans spektroskopisi devreleridir [1]. Gerilim bölücü devreleri basitliği sebebiyle elektro-kimyasal sensörlerin kullanıldığı e-burun sistemlerinde en çok tercih edilen arayüz

devreleridir. Wheatstone köprüsü ise gerilim bölücüye göre yüksek kazancından dolayı düşük sensör direnç değişimlerin meydana geldiği devrelerde tercih edilir.

Akustik dalga sensörlerinde (QCM, KSD, YSD) arayüz devresi olarak, genellikle iki portlu veya bir portlu rezonatör filtre devreleri kullanılır. Bir portlu olanı hem giriş hem çıkış portu olarak kullanılırken, iki portlu olanında giriş çıkış portları ayrıdır [1].

Sensörden elde edilen farklı direnç değerlerine göre, farklı işaretler üretmesini sağlayan direnç kontrollü osilatör devresi de arayüz devrelerinde yaygın kullanılmaktadır [90]. Bu örnekler kullanılan sensöre göre çoğaltılabilir.

Bu çalışmada ise; metal oksit sensör verilerini elektriksel işarete dönüştürmek için gerilim bölücü devre arayüz devresi olarak seçilmiştir.

1.4.3. Elektronik Birim

Sensörlerden alınan işaret elektriksel işarete dönüştürüldükten sonra bilgisayarda işlenebilmesi için yeterli değildir. Bu nedenle işaret iyileştirme devreleri kullanılır. En çok kullanılan işaret iyileştirme devreleri yükselteç devreleri, buffer devreleri ve süzgeç devreleridir. Buffer devreleri farklı elektronik katları izole etmek ve empedans yük hatalarını engellemek için kullanılır. Yükselteç devreleri işaretin analog-dijital dönüştürücüye uygulanacak seviyeye gelmesini sağlar. Süzgeç devreleri sensörlerden gelen istenmeyen frekans bileşenlerini filtrelemeye yarar. Bunların haricinde, işaretin dijital işaret işleme evresine uygun hale gelmesi için, sensörlerden alınan işaret doğrusal olmadığında veya eksiklikler olduğunda; türev alıcı, integral alıcı, doğrusallaştırıcı, logaritma alıcı gibi ek devrelerde kullanılabilir [1].

1.4.4. İşaret Koşullama Birimi

Sensör cevapları çeşitli gürültüye maruz kalırlar. Sensörlerden kaynaklanan ısı gürültü, analog devrelerden kaynaklanan iletim gürültüsü, analogdan dijitale dönüştürme evresindeki kuantalama gürültüsü, sayısal işaret işlemede eklenen gürültüler e-burun sistemini en çok etkileyen gürültülerdir. Ama bu gürültülerin hiçbiri, sensörlerdeki sapma ve sensör cevaplarının tekrarlanabilirliğinin zayıf olması kadar sensör cevaplarını olumsuz etkilemez. Performansı artırmak ve bu gürültüleri filtrelemek için sayısal filtre kullanılabilir. Sayısal filtreler, dürtü (impuls) cevabına göre özyineleme filtreler (Infinite

Impulse Response, IIR) ve özyinelemesiz filtreler (Finite Impulse Response, FIR) olmak üzere ikiye ayrılırlar. Savitsky-Golay filtreleri kimyasal ölçümlerde en çok kullanılan özyinesiz filtre tipidir. Polinom filtrelerinin bir çeşididir ve filtrelemek için genellikle 2. veya 4. derecelerde filtre seçilir [91]. Bu filtre, çoğu e-burun çalışmalarında sıklıkla kullanılan bir geniş bant filtre tipidir.


1.4.5. İşaret Ön İşleme Birimi

Sensör verileri, işaret koşullama ve işaret ön işlemleri sürecinden geçtikten sonra sınıflandırılmak üzere örüntü tanıma algoritmasına gönderilir. Sensör verilerinin örüntü tanıma algoritmasına gidene kadar yapılan işlemler aşağıdaki maddelerde özetlenmiştir:

1. Koku sensörünün cevabı elektriksel işarete dönüştürülmek üzere kullanılan sensörün çeşidine göre arayüz devresine gider.
2. Arayüz devresinden gelen elektriksel işaret analog işaret işleme evreleri olan tamponlanma, filtreleme, kuvvetlendirme gibi devrelerden geçerek sensör işaretinin taşıdığı bilginin gelişmesi sağlanır.
3. Analog işaret sayısal işarete işlemeye maruz kalabilmesi için bilgisayarda depolanmak üzere sayısal işarete dönüştürülür. Sayısal işaret işlemede yapılabilecek işlemler sayısal filtreleme, referans düzeltme (baseline manipulation), boyut indirgeme ve normalizasyondur [92].

1.4.5.1. Referans Düzeltme

Referans düzeltme işaret ön işleme evresinin aşamalarından biridir. Referans düzeltme uygulanmasında amaç sensörlerin en büyük sorunu olan sensör sapmalarının kısa dönem etkisini azaltmaktır [1]. Şekil 1.5’de sensörlerden elde edilen ham işaretler ve hepsine uygulanan referans gaz seviyesindeki farklılıklar gözükmektedir. Hepsini aynı koşullarda değerlendirmeyi sağlamak için referans düzeltme uygulanır.



Şekil 1.5. 8 sensöre limon kokusu uygulandığında elde edilen ham işaret

Bu kısımda literatürde en sık rastlanan referans düzeltme uygulamalarına değinilecektir. Bir veri kümesinde $\ddot{o}=1\dots N_{\ddot{o}}$ koku örneğini, $s=1\dots N_s$ sensör sayısını ve $k=1\dots N_T$ sensör cevaplarının toplam örnekleme sayısını göstermekte olup, sensör cevaplarından elde edilen gerilim değeri ise $V_{\ddot{o},s}(t_k)$ şeklinde ifade edilir. $V_{\ddot{o},s}(t_1)$ sensör cevabından alınan ilk örnek olmak üzere aşağıdaki 3 yöntem sıklıkla kullanılmaktadır [92].

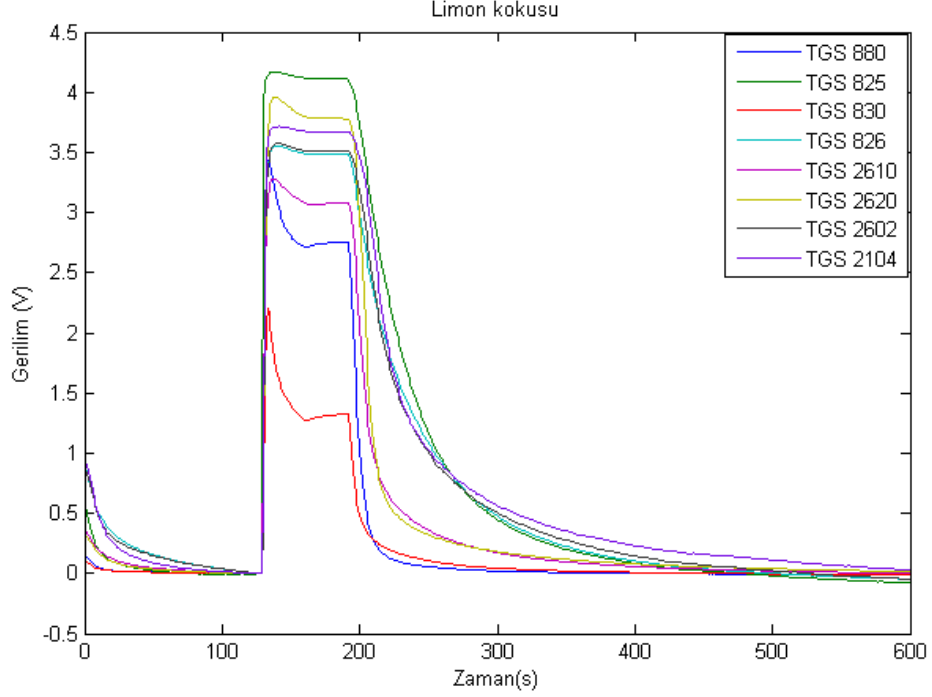
$$V_{\ddot{o},s}^B(t_k) = V_{\ddot{o},s}(t_k) - V_{\ddot{o},s}(t_1) \quad \forall \ddot{o}, s, k \quad (1.2)$$

$$V_{\ddot{o},s}^B(t_k) = V_{\ddot{o},s}(t_k) / V_{\ddot{o},s}(t_1) \quad \forall \ddot{o}, s, k \quad (1.3)$$

$$V_{\ddot{o},s}^B(t_k) = (V_{\ddot{o},s}(t_k) - V_{\ddot{o},s}(t_1)) / V_{\ddot{o},s}(t_1) \quad \forall \ddot{o}, s, k \quad (1.4)$$

(1.2), (1.3) ve (1.4) denklemlerinde $V_{\ddot{o},s}^B(t_k)$ referans düzeltme uygulanmış \ddot{o} . koku örneğinin, s . sensör cevabının, k . örneği olmaktadır. (1.2), (1.3) ve (1.4) denklemleriyle uygulanan yöntemlerin adı sırasıyla fark, bağıl ve oransal referans düzeltmedir. Bu çalışmada veri tabanlarına uygulanan fark referans düzeltme yönteminin diğerlerinden

daha başarılı sonuçlar verdiği gözlemlenmiş ve bu yüzden koku verilerine uygulanmıştır. Şekil 1.6'da ise, Şekil 1.5'deki bu tez çalışması kapsamında elde edilen işaretlere fark referans düzeltme uygulandıktan sonra elde edilen işaretler gözlenmektedir.



Şekil 1.6. 8 sensöre limon kokusu uygulandığında elde edilen ham işaretin fark referans düzeltme ile düzeltilmiş şekli

1.4.5.2. Boyut İndirgeme

Ön işlem aşamasından geçen koku verisinin yüksek boyutlu olmasından veya fazlalıklar taşınmasından dolayı sınıflandırma işlemine uygun hale getirmek için boyutu indirgenir. E-burunlarda kimyasal gaz sensörlerinin çapraz seçiciliği yüzünden fazlalık problemi önemlidir. İki veya daha fazla özellik fazlalık olduğunda, tüm veri kümesinin kovaryans matrisi singüler olabilmekte bu da tersinin alınamaması gibi birtakım sorunlara yol açmaktadır. Bu ve bunun gibi sebeplerden boyut indirgeme gerekli olmaktadır. Ya öznelik çıkararak ya da çıkarılan özneliklere öznelik seçme uygulayarak boyut indirgeme gerçekleştirilebilir [1]. Öznelik seçme öncelikli özneliklerden oluşan bir alt küme seçme işlemi iken, öznelik çıkarma öncelikli özneliklerin bir fonksiyonuna dayanan işlemdir.

Öznitelik çıkarma her örnekten ölçülenlerin sayısını azaltmak için sensör cevaplarından genel tanımlayıcı parametreler çıkartma işlemi olarak da değerlendirilebilir. Çoğu durumda parametre sürekli durum, son veya maksimum durum gibi tek alınır.

1.4.5.2.1. Öznitelik Çıkarma

Kokular birçok kimyasal bileşiklerden oluşurlar. Kokuyu tanımlamak için her bileşenin konsantrasyonu kullanılabilir. Eğer kokuyu tanımlamak için kokunun bileşenlerinin konsantrasyonu kullanılırsa, her konsantrasyon kokunun özneliği olarak kullanılabilir [93]. Konsantrasyon vektörleri kokunun örüntüleridir. Ama çoğu zaman kokular yüzlerce hatta binlerce bileşenden oluştuğu için kokunun tam örüntüsünü çıkarmak bu yöntemle imkansızlaşır. Öznitelik çıkarma işlemi gaz sensörünün tipine bağlıdır. Genelde koku bileşeni sayısı, sensör sayısından çok çok büyüktür. Bu yüzden sensörlerin sürekli durum değeri öznelik olarak seçildiğinde veri kaybı fazladır. Kokular çok kompleks yapılar olduğu için; herhangi bir yöntem bir kaç kokuda iyi iken başka kokularda iyi olmayabilir.

E-burun sensör cevapları incelendiğinde sensör verileri arasında yüksek korelasyon olduğu görülür. Sensörlerden elde edilen verilerden bağımsız konsantrasyon örüntülerini elde etmek gerekir. Bunun için öznelik çıkarma yöntemleri kullanılır.

Bu yöntem az sayılı sensör dizilerinde tercih edilmektedir. Öznitelik çıkarma işleminin hedefi, en uygun sayıda öznelikten maksimum bilgiyi içererek sınıfının doğru tahmin edilmesini sağlamaktır.

İstatistiksel veri analiz yaklaşımları kullanılarak yapılan öznelik çıkarma işlemlerinden Temel Bileşen Analizi (TBA), Doğrusal Ayırıştırma Analizi (DAA) ve Bağımsız Bileşen Analizi (BBA) yöntemleri yaygın olarak kullanılmaktadır.

Bahsedilen istatistiksel yöntemlere ilave olarak 32 iletken polimer sensörden oluşan e-burun verilerine öznelik çıkarma yöntemlerinden olan eğri uydurma, Gardner dönüşümü, çoklu ekponansiyel geçiş spektroskopisi, Pade Laplace ve Pade z-dönüşümü yöntemleri uygulanmıştır [92]. Ayrıca, farklı espresso kahvelerinin ayırımında sürekli durum değeri öznelik olarak çıkarılmıştır [94]. Benzer şekilde, patates cipsini ve patates kremasını ayırt etmek için öznelik çıkarma yöntemi olarak, sürekli durum değeri ile düşen kenarda %90'dan %10'a ulaşma süresi alınmıştır [95]. Aseton ve pentanon gibi farklı basit kokular Fourier dönüşümü, dalgacık dönüşümü, integral alma ve türev alma ile

elde edilen parametrelerden yararlanarak sınıflandırılmıştır [96]. Yine birçok koku, Lorentzian modelinin eğri uydurmada kullanılmasıyla her sensörden 4 öznitelik elde edilerek sınıflandırılmıştır [97]. Susam yağının olgunluğunu algılamada e-burun kullanılmış ve özellik çıkarma yöntemi olarak, belirli saniyelerdeki sensör cevapları alınarak sınıflandırma yapılmıştır [98]. 13 sensörle, 3 farklı Çin şarabını ayırt etmek gibi birçok uygulamada dalgacık dönüşümü kullanılmıştır [99-101]. Sensör dinamik cevaplarından integral alma, çarpıklık katsayısı, standart sapma kullanılarak; 9 farklı koku, 7 sensör kullanılarak sınıflandırılmıştır [102]. Süspansiyonlardaki yalnız kolonilere dayanan bakterilerin ayrımı e-burunla yapılırken, bir sürekli durum parametresi ve bir dinamik durum parametresi kullanılmıştır [103]. 12 sensör kullanılarak yapılan bu özellik çıkarmada, maksimum değer ve 5 ile 20 s arasındaki işaretin türevi kullanılmıştır. Bu yöntem haricinde faz uzayında işaretin maksimum değerinin, türevinin minimum değerine oranı da özellik çıkarma yöntemi olarak kullanıldı [104-106]. Gabor fonksiyonu da özellik çıkarmada kullanılan yöntemlerden biridir [107].

Literatür incelendiğinde çoğu durumda sürekli durum parametresi olarak, işaretin sürekli durumundaki son veya maksimum değeri alınır [108]. Genel olarak değerlendirildiğinde, sensör cevabından öznitelik çıkarma işlemi, e-burun uygulamalarında aşağıdaki gibi 3 gruba ayrılabilir [92].

Alt-örnekleme yöntemi: Kokunun uygulandığı süre boyunca sensör cevaplarının farklı zamanlarda örneklenmesi ile elde edilen verilerin öznitelik olarak alınması metodudur. Bu çalışmada kullanılan veri tabanlarında en başarılı sonuçlara bu metot kullanılarak ulaşılmıştır.

Parametre çıkarma yöntemleri: Geçiş cevabı birkaç parametre seçilerek sıkıştırılabilir. Bu parametrelere örnek olarak yükselme zamanı, iyileşme zamanı, maksimum, minimum cevaplar, eğim veya eğrinin integrali, türevi gibi örnekler verilebilir. Bu yöntem, bu çalışmadaki koku veritabanlarına uygulanmış ve sonuçları alt örnekleme metodu ile karşılaştırılmıştır.

Sistem-tanımlama yöntemi: Deneysel geçiş cevabına teorik model uydurularak, bu modelin parametreleri kullanılabilir. Eğri uydurma ve belirlenen eğrinin parametrelerinin öznitelik olarak seçilmesiyle elde edilen yöntemdir.

1.4.5.2.2. Öznitelik Alt Kümesi Seçimi

Öznitelik alt küme seçiminin hedefi, en uygun sayıda öznitellikten (sensörden) maksimum bilgiyi içererek sınıfının doğru tahmin edilmesini sağlamaktır. Tüm öznitelik kümesini kullanmaktansa, gerekli öznitelik alt kümesini kullanmak çoğu uygulamada daha başarılı sonuç verdiği gözlenmektedir. Ayrıca öznitelik seçmedeki tek amaç sadece ilişkili öznitelikleri seçebilmek değil, aynı zamanda öznitelik uzayının boyutunu azaltmaktır.

Öznitelik alt kümesi seçme işleminde alt kümeyi belirleme, sistematik veya yapılandırılmış bir yöntemle belirlenebilir. Öznitelik alt küme seçim işleminde çok çeşitli yöntemler kullanılmıştır. Bunların içinde en düz yaklaşım ise, tüm öznitelik kombinasyonlarının denenmesidir. Bu şekilde optimal çözüm elde edilebilir. Aynı şekilde dal ve sınır araması popüler arama algoritmalarındandır ve optimum kümeyi bulmayı garanti eder [109]. Ama işlem yükünden dolayı bu algoritmalar çok fazla özniteliğin olduğu sistemlerde tercih edilmezler. Yine e-burun uygulamalarında, alt küme seçiminde genetik algoritmaların (GA) kullanımına sıklıkla rastlanmaktadır [110]. GA biyolojik evrimleşme sürecini taklit eden bir arama algoritmasıdır [111]. Daha basit yöntemlerden olan ardışıl ileri seçme (AİS, sequential forward selection) ve ardışıl geri seçme (AGS, sequential backward selection) algoritmaları da öznitelik seçiminde sıklıkla kullanılan arama algoritmalarıdır [112]. AİS yönteminde öznitelik kümesi boş seçilir ve her seferinde bir öznitelik eklenerek en uygun öznitelik alt kümesini bulmayı amaçlarken, AGS yönteminde öznitelik kümesinin tamamı alınır ve her döngüde bir öznitelik veya öznitelikler grubu ayrılarak en uygun alt küme elde edilmeye çalışılır. İşlem hızı yüksek olan bu iki algoritmanın dezavantajı ise; AİS’de öznitelik bir kez eklendikten sonra geri çıkartılamaz, AGS’de ise çıkartılan öznitelik bir daha eklenemez.

Bunlara ilaveten TBA, DAA ve BAA’da özniteliklerin sayısını azaltmakta kullanılabilir.

1.4.5.3. Normalizasyon

Normalizasyonun temel amacı, verileri genel veriler içinde ağırlıklandırarak verilerin kolay yorumlanmasını sağlamaktır [113]. Normalizasyonu yerel ve global normalizasyon olarak ikiye ayırabiliriz. Lokal normalizasyon yalnız bir koku için öznitelik dizilerine uygulanır. Koku yoğunluğunun değişkenliği ve sensör kaymalarının neden olduğu

örnekten örneğe ortaya çıkan değişikliği kompanze etmek için yapılır. Lokal normalizasyonda en çok kullanılan yöntem ile gösterilen vektör normalizasyonudur.

Global normalizasyon, tüm veri tabanlarındaki kokular için bir özniteliğe uygulanır. Öznitelik ölçeklemedeki farkları kompanze etmek, farklı parametrelerden çıkarılan farklı büyüklükteki öznitelikleri aynı anda değerlendirebilmek üzere uygulanır. Oto-ölçekleme (auto-scaling) ve orta-merkezleme (mean-centering) olmak üzere iki yöntemle yapılır.

Oto-ölçekleme: Tüm öznitelikler 0 ile 1 arasında ölçeklenecek şekilde (1.5) denklemiyle elde edilir.

$$R_s^k = (X_s^k - \min(X_s^k)) / (\max(X_s^k) - \min(X_s^k)) \quad (1.5)$$

(1.5) ifadesindeki ‘max’, vektörün maksimum değerini, ‘min’ ise minimum değerini alan operatördür.


Orta-merkezleme: Ortalama ve standart sapmadan yararlanarak yapılan ölçekleme (1.6) ifadesiyle ölçeklenir.

$$R_s^k = (X_s^k - \text{mean}(X_s)) / \text{std}(X_s) \quad (1.6)$$

(1.6) ifadesindeki ‘mean’, vektörün ortalamasını alan veri iken, ‘std’ standart sapmasını alan vektördür. Bu çalışmada; normalizasyon, çıkarılan özniteliklere uygulanmış ve sınıflandırıcıya normalize edilmiş öznitelikler uygulanmıştır.

1.4.6. Örüntü Tanıma Birimi

E-burunla koku tanıma, sensörlerden alınan elektriksel işaret sayısal işarete çevrildikten sonra tanıma işlemi için bilgisayara gönderilir. Sayısal işarete dönüşmüş işaret Şekil 1.7’de verilen aşamalardan geçerek tanımlanmaya çalışılır.



Şekil 1.7. Sensörlerden elde edilen işaretin işaret işleme aşamaları

Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır [114]. Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirir. İnsan örüntü tanıması, geçmiş tecrübelerle dayalı öğrenme esaslıdır. Böylece, insanlar pratikte karşılaştığı örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Örüntü tanımanın tanımı yapılacak olursa; aralarında ortak özellik bulunan ve ilişki kurulabilen karmaşık işaret örneklerini bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırma işlemi olduğu söylenebilir [115]. Örüntü tanıma tekniklerinin uygulamaları birçok mühendislik, tıp, askeri ve bilim alanına açıktır. Örnek olarak ses tanıma, EEG sınıflama, radar hedef sınıflama, biyomedikal kontrol, veri madenciliği verilebilir. Örüntü tanıma olarak bilinen bu uygulamalar, makina öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır.

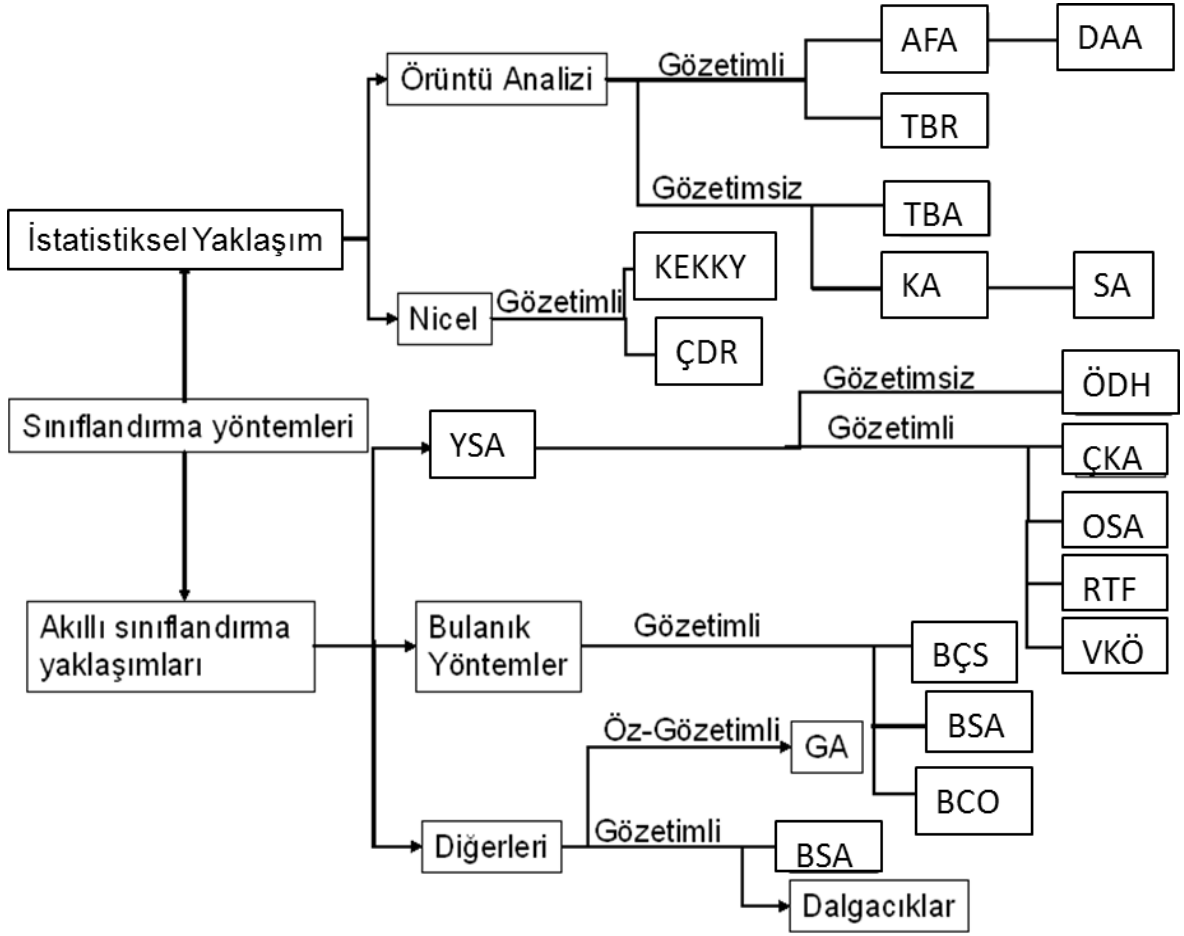
Her bir kokunun kendine has özellikleri vardır. Birçok kokuyu küme şeklinde ifade etmekle kendine has özellikleri olan kokuların veri tabanı oluşturulabilir [116]. Bu veri tabanı ile örüntü tanıma sisteminin eğitilmesi için veriler oluşturulmuş olur. Bu eğitme işleminin amacı koku tanıma işlemi sırasında çeşitli kokuların sistem tarafından otomatik algılanabilmesi için sisteme öğretilmesidir. Çoğu örüntü tanıma sistemi istatistik, yapay sinir ağlar ve nöromorfik algoritmaların işbirliğiyle gerçekleştirilmektedir [116].

Günümüzde veri analizi yapılırken makine öğrenmesi veya kimyevi ölçümlerin sıklıkla kullanılmasından dolayı çok sayıda örüntü tanıma yöntemi mevcuttur. Uygun örüntü tanıma yöntemi seçilirken analiz edilecek verinin yapısı da iyi bilinmelidir.

Sensörlerden elde edilen işaretler örüntü tanıma birimine gelene kadar işaret koşullama ve işaret ön işleme aşamalarından geçerler. İşaret koşullama, işaretlerin filtre edildiği, farklı tekniklerle dönüştürüldüğü veya işaret modellemesinin yapıldığı bölümdür. İşaret ön işleme biriminde ise referans düzeltme uygulanır, işaretlerin boyutları indirgenir, anahtar özellikleri ortaya çıkarılır ve normalize edilir. Örüntü tanıma biriminde ise seçilen öznelik kümesinden tanımlama, sınıflandırma yapılır ve bu karar aşamasıdır.

Sınıflandırma aşamasının amacı, örüntüleri öznitelik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eklemektir. Sınıflandırıcının başarımında iyi belirlenmiş öznitelikler kilit rolü oynarlar. Bu bölümde e-burun uygulamalarında örüntü tanımada sıkça kullanılan farklı sınıflandırıcı türlerinden bahsedilecektir.

Örüntü tanıma yöntemlerini parametrik, parametrik olmayan, gözetimli (eğitici) veya gözetimsiz (eğitici) diye sınıflandırabiliriz. Şekil 1.8’de sıklıkla kullanılan örüntü tanıma yöntemleri gözükmemektedir [1].



Şekil 1.8. Sınıflandırma yöntemleri [1].

Parametrik yöntemlerde verinin dağılımının bir olasılık yoğunluk fonksiyonu ile tanımlanması gerekir. Çoğu durumda veriler sabit ortalamalı ve varyanslı normal dağılıma sahiptir. Bu tekniklerde sistem girişi ile koku vektörü arasındaki ilişki formüle edilebilir.

Sensörlerden alınan veri herhangi bir olasılık yoğunluk fonksiyonu olarak tanımlanamıyorsa parametrik olmayan yöntemler tercih edilir. Bu sınıflandırıcıyla verinin yapısı hakkında varsayım yapılamaz. Bu yönteme örnek olarak uzman sistemler ve yapay sinir ağları verilebilir.

Gözetimli (eğitici) öğrenmede bilinen bir koku kümesi e-buruna verilerek bu kokuları sınıflandırılması sağlanır. Bilinmeyen bir koku verildiğinde bilinen kokuları referans alarak sınıflandırma işini yapar.

Gözetimsiz öğrenme yöntemlerinde sınıfların önceden bilinmesine veya herhangi bir aşamada insana ihtiyaç yoktur. Bu özelliğinden ötürü biyolojik koku alma sistemine daha yakın bir algoritmadır.

İstatistiksel yaklaşımlara örnek olarak TBA, Kısmi En Küçük Kareler Yöntemi (KEKK), Çoklu Doğrusal Regresyon (ÇDR), Temel Bileşen Regresyonu (TBR), Ayrık Fonksiyon Analizi (AFA), DAA, ve Kümeleme Analizi (KA) verilebilir.

Akıllı sınıflandırma yapılarından yapay sinir ağlarına örnek olarak da Çok Katmanlı Algılayıcı (ÇKA), Öz Düzenleyici Haritalar (ÖDH), Radyal Tabanlı Fonksiyon (RTF), Olasılıksal Sinir Ağları (OSA) ve Vektör Kuantalamalı Öğrenme (VKÖ) verilebilir. Bulanık yöntemlerden Bulanık Çıkarım Sistemi (BÇS), Bulanık Sinir Ağları (BSA) ve Bulanık C Ortalamaları (BCO) sıklıkla kullanılmaktadır.

Tablo 1.2’de şimdiye kadar yapılmış e-burunlarda sıklıkla kullanılmış sınıflandırma yöntemleri verilmiştir [117].

Bu çalışmada sınıflandırma yöntemlerinden Bayes sınıflandırıcılar, DDA, destek vektör makinaları (DVM) ve en yakın k komşuluğu (k-EYK) e-burun verilerine uygulanmıştır.

1.4.6.1. Bayes Sınıflandırıcılar

Bayes sınıflandırıcı, Bayes teoremini kullanan her özneliğin birbirinden bağımsız olduğunu varsayarak örneklerin hangi sınıfa hangi olasılıkla ait olduğunu belirten bir sınıflandırıcıdır.

Bir olayın eğitim verilerine göre hangi sınıfta olma olasılığı daha yüksekse o sınıfa ait olduğu tahmin edilmesine dayanan bir algoritmadır. Gerçekleşmesi kolay ve çoğu durumda iyi sonuçlar veren bu sınıflandırıcının da dezavantajları vardır. Bunlardan biri, özneliklerin birbirinden bağımsız varsayımının gerçek hayatta gerçekleşmesinin zor

olmasıdır. Diğeri ise öznelikler arası ilişkinin modellenememesidir. E-burun uygulamalarında da kullanılan bu yöntem örnek olarak hastane çevresinde meydana gelen kulak, burun ve boğaz bakterilerini sınıflandırmada kullanılmaktadır [118-120].

Tablo 1.2. E-burunda literatürde kullanılan sınıflandırma yöntemleri [1].

Yöntem	Doğrusal	Öğretmenli	Sensör Çeşidi ve Sayısı	Hedef Koku
TBA	Evet	Hayır	8 MOS 12 MOS 4 CP 18 karışık 1 BAW	Uçucu bileşikler Alkoller Alkollü içkiler Kağıt çeşitleri Şaraplar
Kümeleme Analizi (KA)	Evet	Hayır	12 MOS 8 MOS 8 MOS CP	Alkoller Kahveler Viskiler Domuz gübresi
Yapay sinir ağları (Hamming ağı)	Hayır	Hayır	8 MOS	Alkoller
Yapay sinir ağları (Kendi kendini örgütleyen (ÖDH) ağlar)	Hayır	Hayır	12 MOS 6 MOS	Kahve Bakteri yaşı
Yapay sinir ağları (geri yayımlı-BP)	Hayır	Evet	6 QCM 6 QCM 12 MOS 6 QCM 4 MOS 1 MOS	İçecekler Viski Alkoller Parfüm ve çiçekler Bakteri Şarap
Yapay sinir ağları (öğrenim vektör nicemleme (VKÖ) ağları)	Hayır	Evet	8 MOS	Viski
Yapay sinir ağları (URT ağları)	Hayır	Kendi	12 MOS	Alkol ve kahveler

1.4.6.2. Doğrusal Ayırma Analizi

Ayırma analizinde ortak özellikleri birbiri içine girmiş grupları ayırmak için, grup ortalama vektörlerini ayıran fonksiyonlar üretir [121]. İzdüşüm yönleri, sınıf içi örnekleri birbirine uzaklıklarını minimum yapacak, sınıflar arası örneklerin uzaklıklarını maksimum yapacak şekilde belirlenir. Böylece bulunan izdüşüm yönleri sınıfları başarıyla ayırmış olur. Doğrusal Ayırma analizinde verinin düzgün dağılımlı olduğu varsayılır [122]. Sadece

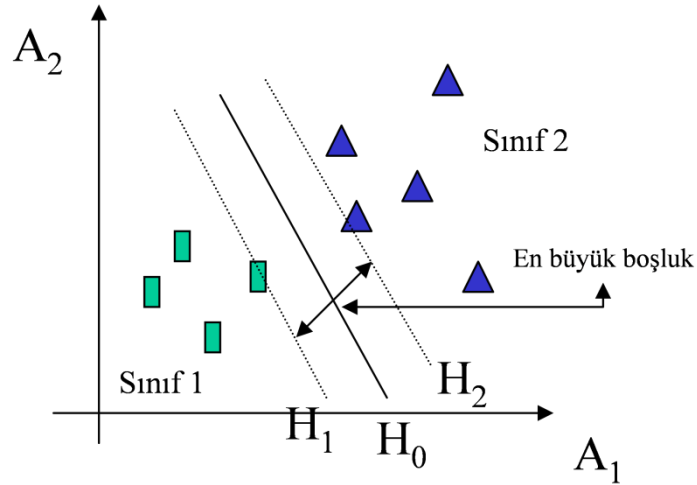
sınıflandırmada değil, öznitelik çıkarmada da kullanılır. Bu çalışmada sadece sınıflandırma amacıyla kullanılmıştır.

1.4.6.3. Destek Vektör Makinaları

Bu çalışmada kullanılan sınıflandırma yöntemlerinden biri de DVM'dir. Bu yöntem sınıflandırmayı doğrusal veya doğrusal olmayan bir fonksiyon yardımıyla yerine getirirken, veriyi birbirinden ayırmak için en uygun fonksiyonun tahmin edilmesi esasına dayanır [123].

Doğrusal olarak birbirinden ayrılabilmeye Şekil 1.9'daki örneği verebiliriz. İki boyutlu uzay için düşünürsek veriyi birbirinden farklı birçok doğrunun ayıracağı, şekilde gözükmektedir. Çok boyutlu uzayda bu doğruların yerini hiper düzlemler almaktadır. Buradaki temel sorun verileri birbirinden ayıracak en uygun doğrunun seçilmesidir.

Bu yöntemde en uygun düzlem, arasında en büyük boşluk bulunan iki hiper düzlemin ortasından geçen hiper düzlemdir. Aralarında en büyük boşluk bulunan iki hiper düzlem elde edilirken yararlanılan gözlemlere ise destek vektörler adı verilir. DVM, e-burun uygulamalarında farklı koku veri tabanlarında kullanılmış olup güçlü sınıflandırma türlerinden biridir [124-127].



Şekil 1.9. Doğrusal olarak birbirinden ayrılabilen veriler [124].

1.4.6.4. En Yakın K-Komşu Sınıflandırıcı

Geniş uygulama alanı bulan k-EYK uygulaması basit ve parametrik olmayan örüntü tanıma yöntemleri arasındadır. Sınıfları belli olan bir örnek kümesindeki gözlem değerlerinden yararlanarak, örneğe katılacak yeni bir gözlemin hangi sınıfa ait olduğunu belirlemek amacıyla kullanılır [123]. Yeni gözlem ile mesafe olarak en yakın k-komşusundaki gözlemlerin sınıfı dikkate alınarak yapılan sınıflandırmadır. Basit olması nedeniyle e-burun uygulamalarında özellikle diğer yöntemlerle kıyaslamada çok tercih edilen bir yöntemdir [127-129].

1.5. Tez Çalışmasının Amacı ve Literatüre Katkıları

Bu tez çalışmasının hedefleri aşağıdaki gibi sıralanmıştır:

1. Bu alanda üniversite kapsamında yapılan ilk, ülke kapsamındaki nadir e-burun düzeneklerinden olan, kokunun tanınmasını sağlayan e-burun düzeneğinin yapısını anlamak, düzeneği iyileştirme için neler yapılabileceği konusunda deneyimlenmektir. İleriki çalışmalarda deney düzeneğinin gerçek zamanlı ve mobil hale gelmesi için koku alma sisteminin aşamalarının iyi anlaşılması gereklidir.
2. Sensörlerde meydana gelen en önemli sorunlardan biri olan uzun dönemli ve kısa dönemli kaymaların etkisini azaltmak için, donanımsal ve yazılımsal olarak yapılacakların belirlenmesidir.
3. Farklı veri tabanları için sensörlerden elde edilen koku verilerini en iyi temsil edecek özneliklerin çıkarılmasını sağlamak ve bunlar arasından en uygun sensör seçimini gerçekleştirmektir.
4. Koku verilerini temsil eden öznelikleri en uygun ayıracak sınıflandırma algoritmasının tespitidir.
5. Bütün olarak düşünüldüğünde; E-burun sisteminin hangi alanlarda başarılı bir şekilde uygulanacağını belirlenmesi ve geliştirilmesi için üzerine eklenmesi gerekenlerin tespitidir.

Bu hedefler doğrultusunda bu tez çalışmasının literatüre katkıları aşağıda sıralandığı gibidir:

1. Taşıyıcı gaz işaretinin, örnek koku işaretinden çıkartılmasıyla sensor kaymalarının meydana getirdiği problem azaltılmıştır.
2. Özellik çıkarmada daha önce e-burunla ilgili çalışmalarda sıklıkla kullanılmayan alt örnekleme metodunun başarısı kanıtlanmıştır.
3. Önerilen hibrit sınıflandırma yöntemiyle e-burun verilerini sınıflandırma başarısı artırılmıştır.
4. Önerilen sınıflandırma yönteminin sağladığı avantajlardan biri, karar ağacı yapısındaki sınıflandırıcılarda kullanılan özelliklerin her sınıflandırıcının ayırdığı veriye göre değişerek algoritmaya esneklik sağlamasıdır.
5. Önerilen sınıflandırma yönteminin sağladığı avantajlardan bir diğeri ise karar ağacı yapısındaki sınıflandırıcılarda kullanılan yöntemlerin her sınıflandırıcının ayırdığı veriye göre değişme imkanına sahip olması ile algoritmaya esneklik sağlamasıdır.
6. Balık veri tabanı için daha önce balık tazeliği tespitinde sisteme uygulanan balıklar +4° C de saklanırken, bu çalışmada balığın saklama koşulları göz önünde bulundurularak, daha iyi korunmuş balıkların tazeliği ayırt edilmiş, yani zorlaştırılmış sınıflandırma probleminin üstesinden önerilen algoritmayla gelinmeye çalışılmıştır.

1.6. Tez Çalışmasının Kapsamı ve Organizasyonu

E-burun ile koku tanıma sistemleri için, ülkemizde öncü çalışmalardan birini oluşturan bu tez çalışmasının bölümlerinin organizasyonu aşağıdaki gibidir:

Birinci bölümde; çalışmanın konusu ve bununla ilgili olan e-burun yapısı, e-burunun etkilendiği biyolojik burundan ve e-burunu oluşturan birimlerden genel olarak bahsedilmiştir. İkinci bölümü yapılan çalışmalar kısmı oluşturacak olup, donanımsal olarak düzeneği kurulan e-burun sisteminden ve bu sistemde kullanılan elemanlar ve kullanım amaçlarından bahsedilmiştir. Bunları takiben, e-burunun yazılımsal birimlerinde, işaret ön işlem aşamasında, öznitelik çıkarımı, öznitelik seçiminde ve sınıflandırma biriminde bu tezde kullanılan yöntemlerden detaylı olarak bahsedilerek ikinci bölüm sonlandırılmıştır. Üçüncü bölüm olan bulgular ve irdeleme kısmında, ikinci bölümde bahsedilen yöntemlerin

MATLAB’da uygulanması sonucunda elde edilen bulgular; tablo, grafik ve şekillerle gösterilmiş ve irdelenmiştir. Üçüncü bölümde irdelenen sonuçlar, dördüncü bölümde genel olarak değerlendirilmiştir. Beşinci bölümde ise; bu çalışmanın geliştirilmesi yönünde, gelecekte yapılabilecek çalışmalar önerilmektedir. Altıncı bölümde, tez çalışmasında yararlanılan kaynaklar verilmiştir. Özgeçmiş bölümüyle tez çalışması sonlandırılmıştır.

2. YAPILAN ÇALIŞMALAR

Literatürde yer alan çalışmalar e-burun sisteminin daha az hatayla geniş sistemlere uygulanmasını hedeflemektedir. İyileştirilmeye çalışılan unsurlar birkaç başlık altında toplanabilir:

- Geniş ölçekte kullanılabilecek ideal sensörün bulunamamasından dolayı geniş uygulama alanında kullanılabilecek en ideal sensörün bulunması hedefler arasında yer almaktadır.
- Sensör işaretlerinin ön işleme aşamasında, sensör cevaplarını gürültüden de fazla etkileyen, kısa dönem ve uzun dönem kaymalarını en aza indirgeyecek algoritmaların geliştirilmesidir.
- Sensörlerin çevresel koşullardan en az etkilenecek donanıma ve yazılıma sahip olmalarıdır.
- E-burunun seçiciliğinin, hassasiyetinin, kararlılığının ve tekrarlanabilirliğinin artırılmasını sağlayacak sensörlerin seçimi, e-burun düzeneği veya örüntü tanıma algoritmalarının geliştirilmesi hedefler arasındadır.

Yukarda sıralanan hedeflere ulaşmak için çalışmaların son 10 yılda hız kazandığı gözlenmektedir. Bu tez kapsamında ise yapılan çalışmalar aşağıda maddeler halinde sıralanmaktadır.

1. İlk olarak e-burun deney düzeneği kuruldu. Bu deney düzeneğiyle farklı veri tabanları elde edildi.

2. Bu tez kapsamında önerilen yöntemle; sensör işaretlerinin ön işleme aşamasında, ortam havasının çıkarılmasıyla sensör cevaplarında meydana gelen kaymaların etkilerinin azaltıldığı gösterildi.

3. Sensör işaretlerinden kokuyu en iyi tanımlayacak öznelik çıkarma yöntemleri incelendi ve karşılaştırıldı. Literatürde sıklıkla kullanılmayan, ama bu çalışmada başarıyla kanıtlanan alt örnekleme yöntemi sunuldu ve e-burun uygulamaları için önerildi.

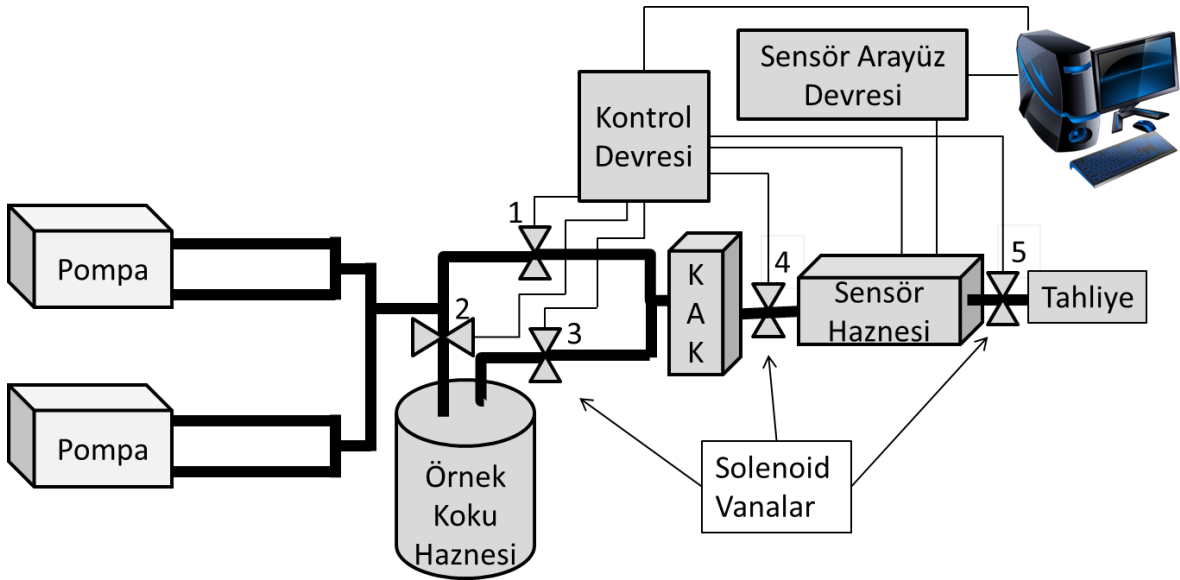
4. Elde edilen özneliklerin sensör işareti ile korelasyonunu maksimize eden, diğer özneliklerle korelasyonunu minimize eden öznelik seçme işlemi uygulandı. Tez kapsamında önerilen yöntemle uygulanan öznelik seçme işleminin başarıyı nasıl etkilediği ve arttırdığı gösterildi.

5. Önerilen yöntemle sensör işaretlerinin sınıflandırılması yapıldı ve sınıflandırma başarısının bu yöntemle arttırıldığı 4 veri tabanı için kanıtlandı.

Yapılan çalışmaların detayları ve içerikleri hakkında genel bilgiler aşağıda verilmektedir.

2.1. Elektronik Burun Deney Düzeneği

Bu tez çalışmasında, deneysel çalışmada kullanılan e-burun modeli verilecektir. Deneysel model kurulurken birçok deney düzeneğinden yararlanılmıştır [88, 93, 130-132]. Bu çalışmada kullanılan deney düzeneğinin blok şeması Şekil 2.1’de verilmektedir.



Şekil 2.1. E-burun deney düzeneğinin blok şeması


İlk olarak tanımlanacak koku molekülleri, örnek koku haznesine yerleştirilir. Bu toplama kabına doldurulan koku molekülleri hava pompası veya kuru hava tüpünün basıncından yararlanarak sensör haznesine iletilir. Bu tez çalışmasında referans koku olarak kuru hava veya ortam havası uygulanmıştır. İtici gücü kuru hava tüpü sağlıyorsa, referans gaz kuru hava olurken, itici gücü hava pompası sağlıyorsa, referans gaz ortam havası olur. Örnek koku veya referans koku sensör haznesine iletilirken sabit hızda sensörlere uygulanmasını sağlayacak kütle akış kontrolöründen (KAK) geçerek sensör haznesine ulaşır. Sensör haznesinde bulunan sensör dizisi gelen gaz moleküllerine göre

çıkış gerilimleri üretir. Bu çıkış gerilimleri sensör arayüz devrelerine iletilir ve veri elde etme kartıyla (data acquisition board) sayısal olarak çevrilir. Bu sayısallaştırılmış sensör cevapları bilgisayara gönderilerek kokuların sınıflandırılması yapılır. Koku tanıma işlemini gerçekleştiren aşamalarda gerekli olan ve kurulan sistemler aşağıda ayrı ayrı incelenmektedir.

2.1.1. Örnek Koku Haznesi

Bu haznenin görevi test altındaki koku kaynağı için uygun bir ortam yaratmak ve yalıtımı sağlamaktır. Toplama kabı olarak 500 ml lik cam kavanoz veya 1000 ml lik şekil 2.2’de gösterilen dibi yuvarlak iki boyunlu cam balon kullanılmıştır. Cam malzeme seçilmesinin sebebi koku haznesinin önceki kokulardan etkilenmemesini sağlamaktır.

0.625 cm çapında biri gaz girişi diğeri gaz çıkışında kullanılmak üzere iki deliği olan metal kapak kullanıldı. Şekil 2.2’de örnek toplama kabının ayrıntılı çizimi ve şekli görülmektedir. 2 nolu deliğe 15 cm uzunluğunda, 2 cm’si kapağın altında kalacak şekilde plastik bir tüp yerleştirilir. 1 nolu deliğe ise 30 cm uzunluğunda e-burunun koku girişine bağlanacak plastik tüp yerleştirilir.



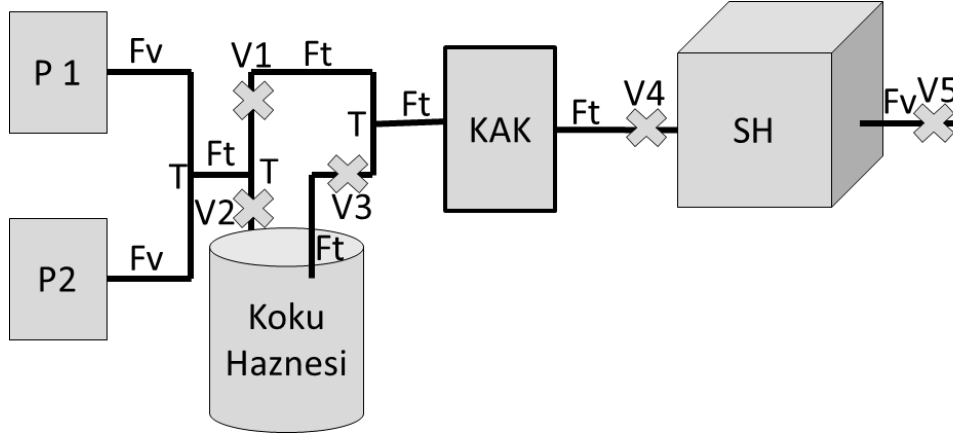
Şekil 2.2. a) İki boyunlu cam balon b) Cam kavanoz

Sıvı koku kaynağı algılanmaya çalışıldığında birinci borudan gelen hava ile hava kabarcığı etkisi oluşturulur. Bu karıştırma işlemi uçucu koku moleküllerinin koku kaynağından ayrılmasını artırır. Benzer karıştırma olayı etkisi tortulu koku kaynaklarında da oluşur (örneğin kahve tortusu gibi).

2.1.2. Koku İletim Sistemi

Koku iletim sisteminin iki önemli görevi vardır. Bunlardan birincisi koku moleküllerini koku kaynağından sensör dizisine taşımak, ikincisi ise sensör haznesini diğer koku örneği için hazırlamak ve temiz tutmaktır.

Koku iletim sistemi 2 hava pompası, 1 kuru hava tüpü, 5 Solenoid vana, T şeklinde pirinç kaplı bağlayıcılar, dış çapı 0.25 inç, iç çapı 0.17 inç olan plastik vinil tüp ve teflon bağlantılardan oluşmuştur. Şekil 2.3’de koku iletim sisteminin blok şeması, Şekil 2.4’de ise iletim sisteminin elemanları gözükmemektedir. Teflon bağlantılar, örnek kokunun geçtiği tüm koku iletim sisteminde elemanları birbirine bağlamakta kullanılır.




Şekil 2.3. Koku iletim sistemi blok şeması

Koku iletim sisteminde kullanılan elemanların teknik özellikleri Tablo 2.1’de ve şekilleri Şekil 2.4’de verilmektedir.

Tablo 2.1. Koku iletim sistemi elemanları ve teknik özellikleri

Adı	Görevi	Özellikleri
SH	Sensör haznesi	Alüminyum kutu, Hacmi = 575 cm ³
V1,V2,V3,V4,V5	Minyatür Solenoid vanalar	Bacak çapı = 0.25 inç
Ft, Fv, T	Bağlantılar: teflon boru, plastik boru, T şekli pirinç bağlantı	Dış çap = 0.25 inç İç çap = 0.17 inç
P1, P2	Hava pompası	Akış hızı=1000 cm ³ /dak Sistem akış hızı=33 cm ³ /sn

Malzeme olarak teflonun seçilme nedeni çoğu kimyasalla reaksiyona girmemesi ve kokusuz olmasıdır. Ayrıca teflon malzeme sayesinde, bir önceki kokunun o anki uygulanan kokuya etkisi en aza indirgenmektedir. Tüm test edilen kokular hava pompalarıyla plastik tüplerden geçerek dışarı atılmaktadır. Koku iletim sisteminin P1 ve P2 pompası örnek koku toplanma kabından koku alma haznesine doğru itici etki yaratmakta kullanılır. Böylece örnek koku molekülleri koku kaynağından çekilir ve sensör uçlarından geçerek dışarı atılır. Solenoit vanalar gazın akış yönünü belirlemekte ve örnek kokunun sensör haznesinde belirli bir süre muhafaza edilmesinde kullanılır. Böylece koku moleküllerinin sensör haznesinde kalması sağlanarak sensörlerin sürekli duruma geçmesi amaçlanmaktadır. Bu aşamada işaret işleme aşamasına büyük katkısı olacak sensörlerin düzgün bir elektriksel işaret üretmesi sağlanmaktadır.



Şekil 2.4. Koku iletim sistemi ve elemanları a) plastik boru, b) T pirinç bağlayıcı, teflon boru ve Solenoid vana, c) hava pompası

Solenoid vanaların koku iletim sisteminde yerleşimleri Şekil 2.3'de yer alan blok şemada görülmektedir. Bu vanalardan dört tanesi giriş hattında yer alırken bir tanesi çıkış hattında yer almaktadır. V1, V2, V3 Solenoit vanaları sisteme referans gazın mı yoksa örnek koku moleküllerinin mi uygulanacağını kontrol etmekte kullanılır. V4 ve V5 Solenoit vanaları ise sensör haznesine iletilen gazların haznede hapsedilip hapsedilmeyeceğinin kontrolünde kullanılır. İki hava pompasının ve kuru hava tüpünün görevleri aynı olup güçlü itici gücü oluştururlar. Sistemin iki farklı taşıyıcı gazın kullanılması durumunda da düzgün çalıştığı tespit edilmiştir.

2.1.3. Akış Kontrol Sistemi

Sensörlerin hepsine aynı akış hızında gaz uygulanmasını sağlamak için akış ve basınç kontrol sistemi kullanılır. Bu akış kontrol sistemi kendine gelen gazı istenilen sabit basınçta ve akış hızında ayarlayarak koku iletim sistemiyle sensör haznesine gönderir. Akış kontrol sisteminin elemanları olan kütle akış kontrol istasyonu ve KAK Şekil 2.5’de gösterilmektedir. Kütle akış kontrol istasyonu ile KAK kontrol edilerek sistemde akan gazın kütle miktarı belirlenmekte ve dolayısıyla akış hızı kontrol edilmektedir.




Şekil 2.5. Akış kontrol sistemi elemanları a) KAK b) Kütle akış kontrol istasyonu

KAK, gaz, sıvı, buhar gibi akışkanlığı olan malzemelerin bir boru veya kanal içinden geçiş miktarını ölçüp kontrol etmeye yarayan cihazdır. Kontrol istasyonundan KAK’tan geçmesi istenen kütle miktarı ayarlanır. Sistemin akış hızı deneysel çalışmalar sonucunda 1000 ml/dk olarak belirlenmiştir.

2.1.4. Koku Sensör Haznesi

Koku alma haznesinin görevi gaz sensörlerini istenmeyen kokudan izole etmek ve sensörlerin sınıflandırılması istenen kokuya maruz kalmalarını sağlamaktır. Bir nevi koku gürültüsünü engellemektir. Alüminyum kapak kutunun üst tarafından vidalanırken conta olarak teflon kullanılmıştır. Bunun sebebi kokusuz olması ve düzgün yüzeyi sayesinde koku moleküllerinin yapışmasını engellemesidir. Koku sensörleri alt tabana yerleştirilmiştir. Koku molekülleri böylece sensörler üzerinden geçerler. Alüminyum kutu

iki sebepten ötürü seçilmiştir. Düzgün yüzeyinden dolayı haznenin içindeki kokunun temizlenmesi daha kolaydır. Gelen kokunun sıcaklığıyla içerdeki sıcak havanın sıcaklık farkını minimize eder. Çünkü metal, cam ve plastikten daha iyi ısı iletkenidir. Metaller arasında çeliğin çok düzgün yüzeyi vardır. Ama çeliği işlemek zor ve maliyetlidir. Ucuz, işlemesi ve malzemeye ulaşımı kolay olduğu için bu deney düzeneğinde alüminyum seçilmiştir. Şekil 2.6'da teknik resmi ve fotoğrafı görülen sensör haznesi için 1 cm kalınlığında alüminyum işlenerek 12.5x6x11 cm hacminde bir kutu oluşturulmuştur.



Şekil 2.6. E-burunda kullanılan sensör haznesi a) teknik resmi b) fotoğrafı


Alüminyum kutunun dar yan yüzeylerinin ortasında koku iletimini sağlamak üzere iki delik vardır. Burada koku iletim sisteminin teflon ve plastik boru bağlantıları bulunmaktadır. Bunlara ilaveten alüminyum kutunun geniş yan yüzeylerinden birinde iki adet kablo çıkışı için erkek konnektör bağlantısı vardır.

2.1.4.1. Gaz Sensörleri


E-burunda kullanılan genel bilgiler kısmında detaylı olarak verilen çok farklı çeşit sensörler mevcuttur. Bu çalışmada Figaro metal oksit gaz sensörleri fiyatının ucuzluğu ve geniş aralıkta kokuyu algılayabildiği için tercih edilmiştir.

Figaro gaz sensörleri genellikle CO, NH₃, ve H₂S gibi indirgen gazlara karşı hassastır. Bu sensörlerin organik bileşiklerin uçucu bileşenlerine, çözücülere, yiyeceklere ve farklı alkol çeşitlerine karşı hassas olduğu saptandı. Ayrıca havayı kirleten sigara dumanına ve araba egzozlarına karşı da duyarlılığı hayli yüksektir.

Bu sensörler 400°C civarında çalıştığından içine monte edilmiş ısıtıcı bulunmaktadır, bu da sensörlerin istenen sıcaklığa gelmesini sağlamaktadır. Sensör cevabı gerilim bölücü R_L direncini algılayan yüzeye seri bağlayarak elde edilebilir. Şekil 2.7’de 8xx serisi ve 2xxx serisi gaz sensörlerine ait teknik resimler, Şekil 2.8’de ise elektriksel eşdeğer devreleri ve kullanılan tüm sensörler verilmektedir.




(a)



(b)

Şekil 2.7. a) TGS8xx serisi gaz sensörleri b) TGS 2xxx [133].

Metal oksit sensörlerin algılama prensibi kimyasal olarak yükseltgenme-indirgenme tepkimelerine dayanmaktadır. Sensörler temiz hava varlığında ısıtıldığında, oksijenin farklı yapıları yarı iletken malzemeden elektron yoğunluğunu geri alarak çekilir. Sonuç olarak yarı iletkenin elektrik direnci artar ve sensör temel durumuna ulaşır. İndirgenir gazlar oksitlere karşı çekim gösterir. Sensör indirgenebilir bir gaza maruz kaldığında, indirgenir gaz sensör yüzeyiyle temas ederek algılanabilir. Çünkü indirgenir gaz, algılama yüzeyinden çekilen oksijen parçalarıyla birleşerek, yarı iletken malzemenin elektron yoğunluğunun artmasına neden olur. Bunun sonucunda sensörün elektriksel direnci düşer [133]. Bu tez kapsamında e-burunda kullanılan sensörlerin teknik özellikleri Tablo 2.2 'de verilmektedir.



Şekil 2.8. a) TGS 8xx serisi b) TGS 2xxx serisi gaz sensörlerinin elektriksel eşdeğer devresi c) E-burunda kullanılan tüm sensörler

Tablo 2.2. Figaro gaz sensörlerinin teknik özellikleri

		TGS 8xx	TGS 26xx	TGS 2104
V_C	Devre Gerilimi (Maksimum)	24 V	5 V	7V
V_H	Isıtıcı Gerilimi	Max 5 V		15 V
R_L	Yük Direnci	Min 450 Ω		
I_H	Isıtıcı Akımı	130 mA	55 mA	91 mA

Geniş uygulama alanına sahip olması için etki alanı farklı 8 metal oksit sensör kullanıldı. Tablo 2.3’de kullanılan sensörler, algıladıkları temel gazlar ve sensörlerin çıkışlarına bağlanan yük dirençlerinin değerleri verilmektedir.

Tablo 2.3. Gaz sensörleri, hedef gazları ve yük dirençleri

Kullanılan sensör adı	TGS 880	TGS 826	TGS 825	TGS 830	TGS 2610	TGS 2620	TGS 2602	TGS 2104
Direnç(k Ω)	5.194	5.611	8.74	3.952	7.6	2.902	3.565	4.834
Hedef gazlar	Hidrojen, amonyak	Amonyak	Hidrojen sülfid	R-113 R-22	Propan, buton	Alkoller, organik buharlar, çözeltiler	Uçucu ve kokulu gazlar	Egzoz gazları

TGS 826 balıklı kokulara hassasiyet gösterirken, TGS 825 ise, kükürtlü kokulara karşı hassasiyet gösterir. TGS 2620 de, ağaç fermantasyonu ve alkol kokularını içeren dar aralıklı hassasiyete sahiptir.

TGS 2602 yüksek hassasiyetli çeşitli kokuları algılayabilmektedir. Bu sensörden tamamlayıcı bilgiyi sağlaması beklenir.

TGS 2610 hidrokarbonlara olan yüksek hassasiyetinden dolayı seçilmiştir. Olgun meyvelerden algılanan koku, olgunlaşma süreci boyunca dışarı yayılan birleşme etkisinin uçucu organik bileşikleridir, bunlar propanol ve butanoldur.

TGS 880 ve TGS 830 yemek yapılırken ortaya çıkan uçucu kokulara ve su buharlarına hassastır [93]. TGS 2104 hava kalitesini veya havadaki egzoz gazlarını algılamakta kullanılır. TGS 8xx sensör tipi TGS 26xx sensör tipiyle karşılaştırıldığında; TGS 8xx sensör tipinin boyut olarak daha büyük ve enerji sarfiyatının daha fazla olduğu gözlenmektedir.

Sensör yük dirençleri sensör haznesinin içine yerleştirmek yerine, sensör haznesinin dışında sensör arayüz bordlarına yerleştirilmektedir. Bu şekilde yapılmak istenmesinin sebeplerinden biri koku sensörlerinin referansını belirlemede, çıkışına bağlanan yük



direncini sensör haznesini açmaya gerek kalmadan müdahale edilebilmesini sağlamaktır. İkinci sebep ise sıcak ortamda çalışırken elektronik parçaların etkilenmesini önlemektir.

2.1.4.2. Sıcaklık ve Nem Sensörü

Metal oksit gaz sensörlerinin ortam sıcaklığındaki değişikliklerinden etkilendiği bilinmektedir. E-burunda 2 adet sıcaklık sensörü kullanılmaktadır. Her koku örneğinde laboratuvardaki sıcaklık ve sensör haznesi içindeki sıcaklık ölçülmektedir. Laboratuvardaki ortam sıcaklığı deney süresince kararlı durumda tutulmuştur.

Uçucu koku molekülünün içeri çekilmesi 10 saniye sürerken, kokunun temizlenmesi 300 saniye sürer.

Texas Instrument firmasının üretmiş olduğu LM35 ısı sensörü; besleme gerilimi minimum 4 V, maksimum 20 V'da, sıcaklık derecesi olarak -55°C ile +150°C arasında çalışmakta, çıkış değeri 10mV/°C , (+/-)1, 0.5 °C doğrulukta ölçüm yapmaktadır [134]. Şekil 2.9'da sensör ve elektriksel eşdeğer devresi gösterilen 3 bacaklı LM35 sensörünün 1 ile 3 nolu bacakları arasında besleme gerilimi uygulanırken, 2 nolu baktan sıcaklıkla doğrusal değişen gerilim değeri alınmaktadır.



Şekil 2.9. a) Sıcaklık sensörü b) Sıcaklık sensörü elektriksel eşdeğer devresi [134].


Bu sensör üzerindeki gerilim değişimi veri elde etme kartının analog girişlerinden birine bağlanmaktadır. Biri sensör haznesinin içine, diğeri dışına olmak üzere iki adet sıcaklık sensörü kullanılmaktadır.

Nem ölçümü için farklı nem değerlerinde empedansı değişen Cybersen firmasının nem sensörü kullanılmaktadır. Bir adet nem sensörü sensör haznesinin içinde ortam nemini ölçmektedir. Deneysel çalışmaların hangi nem düzeyinde yapıldığı kayıt altına

alınmaktadır. Sensörler yüksek sıcaklıkta çalıştığından, sensör haznesinin nemi normal seviyelerde kalmaktadır.

2.1.5. Sensör Arayüz Kartı

Sensör arayüz devresinin amacı yük dirençlerini sabit bir gerilim ile beslemektir. Her sensöre bir yük direnci düşmektedir. Tablo 2.3’de arayüz devresinde kullanılan elemanlar gösterilmektedir. Sabit direnç değerleri literatürdeki çalışmalardan ve sensörlerin üretici firmalarının önerilerinden belirlenmiştir [93, 133]. Devrede kullanılan sensör arayüz devresi Şekil 2.10’da görülmektedir.




Şekil 2.10. Sensör arayüz devresi

2.1.6. Kontrol Arayüz Kartı ve Soğutucu Fan

Kontrol arayüz devresinin görevi veri elde etme devre kartından alınan çıkış işaretleri ile valfleri kontrol ederek gaz akışının istenilen yönde kontrolünü sağlamaktır. Veri elde etme devresinin çıkış işareti, koku iletim sisteminin devrelerinin kontrolünde kullanılmaktadır.

Pompalar harici bir röle ile anahtarlanmaktadır. Kullanılan Solenoit vanalarda 200 mA’de, 24 V DC gerilimde çalışan sargılar kullanılmaktadır. Bu vanaları kontrol etmek için 5 V DC gerilim ile çalışan röleler kullanılmaktadır. Röle devresi Şekil 2.11’de gösterildiği gibi veri elde etme kartından kontrol edilmektedir.




Şekil 2.11. Solenoit vana kontrol devresi

Soğutucu, sensör ısıtıcılardan dolayı sıcaklığı yükselen koku sensör haznesinin sıcaklığını düşürmek için kullanılır. Kişisel bilgisayarlarda kullanılan tipik fanlardan 4 inç çaplı fan seçilerek harici kontrollü olacak şekilde sensör haznesinin uzun kenarına yerleştirilmiştir.

2.1.7. Veri Elde Etme Kartı

Veri elde etme kartının görevi sensörlerden alınan analog işaretleri dijitale çevirip bilgisayara iletimini sağlamaktır. Ayrıca; gaz sensörlerinin çalışma sıcaklığını ayarlamak, koku iletim sistemini kontrol etmek de görevleri arasındadır. Koku iletim sisteminin çalışmasını kontrol etmek için sayısal işaret üretir. Bu çalışmada, Şekil 2.12’de verilen National Instrument firmasının DAQ 6259 veri elde etme kartı kullanılmaktadır [135].



Şekil 2.12. a) DAQ 6259 veri elde etme kartı [135] b) DAQ veri akış blok şeması

Tablo 2.4. Veri elde etme kartı giriş çıkış işaret tanımları

Veri Elde Etme Kartı Giriş-Çıkış Adları	Tanımları	Amacı
R1---R8	Sensör Cevabı	Analog gerilim değerleri sayısalı dönüştürüp bilgisayara iletmek
D0	Solenoit vana 1 kontrolü	Koku iletim sisteminin amacına göre lojik 1 veya 0 göndermek
D1	Solenoit vana 2 kontrolü	Koku iletim sisteminin amacına göre lojik 1 veya 0 göndermek
D2	Solenoit vana 3 kontrolü	Koku iletim sisteminin amacına göre lojik 1 veya 0 göndermek
D3	Solenoit vana 4 kontrolü	Koku iletim sisteminin amacına göre lojik 1 veya 0 göndermek
D4	Solenoit vana 5 kontrolü	Koku iletim sisteminin amacına göre lojik 1 veya 0 göndermek
A0	Sensör Isıtıcı Gerilim kontrolü	Sensörlerin çalışmasını sağlamak amacıyla sıcaklık modülasyonu uygulamak

Şekil 2.12’de veri elde etme kartının giriş çıkış pin sisteminin blok şeması görülmektedir. Tablo 2.4’ de de giriş çıkış işaretlerinin tanımı verilmektedir.

Önerilen koku alıp verme sistemi 4 parçaya bölünmüştür. Her evrenin ne kadar sürede gerçekleşeceğine deneylerden elde edilen deneyimlerle karar verilmiştir.

Veri elde etme kartı ve fonksiyon üretici herhangi bir durumu aktif etme veya etmemeye programlanabilir. Bu özelliklerinden yararlanıp koku tanıma sistemi bilgisayar aracılığıyla kontrol edilmektedir.

2.2. Deney Süreci

Deney düzeneğinin ilk elemanları hava pompaları veya kuru hava tüpüdür. Burada taşıyıcı gaz diğer bir adıyla referans gaz olarak ortam havası veya kuru hava kullanılmıştır. Bu çalışma kapsamında yapılan deney düzeneğinin blok şeması Şekil 2.3'de verilmektedir. Deney süresinin ilk 130 saniyesinde 1, 4 ve 5 vanaları açılarak ve 2 ve 3 vanaları kapatılarak pompa veya kuru hava tüpü vasıtasıyla sensör haznesine referans gaz iletilir. Böylece sensörler bir önceki uygulanan kokudan tamamen arındırılıp başlangıç değerlerine ulaşmaktadırlar. Sensör haznesi 130 s temizlendikten sonra 1 vanası kapatılıp 2, 3, 4 ve 5 vanaları açık bırakılarak koku haznesindeki koku örneği sensör haznesine iletilmektedir. Bu işlem 30 s sonra sonlandırılır. Bundan sonraki 30 s ise tüm vanalar kapalı durumda tutularak sensör haznesine koku örneği hapsedilir. Bu işlem sensör cevabının sürekli duruma ulaşması için yapılmaktadır. Son olarak koku haznesine hapsedilmiş örnek kokunun tahliye işlemi yapılır. Bunun için de 1, 4 ve 5 vanaları açık tutulurken 2 ve 3 vanaları kapatılır. Bu işlem 410 saniye süreyle uygulanır. Kokunun örneklenmesi boyunca deney düzeneğindeki vanaların durumları ve durumlarının süreleri Tablo 2.5'de özetlenmektedir. Deney düzeneğinde koku haznesi olarak 500 ml lik iki boyunlu cam balon kullanılmıştır. Cam balona 2 adet tüp bağlıdır. Bunlardan biri dışarıdan gelen havayı örnek kokuya ulaştırırken, diğeri koku haznesindeki kokuyu sensör haznesine iletmek üzere 3. vanaya bağlanır. 2. vananın buradaki görevi, koku örneği sensör haznesine uygulanmadığı sürece kokuyu örnek toplama kabına hapsetmektir.

Tablo 2.5. E-burun ile koku alıp verme döngüsü

	Aşama adı	Koku İletim Sistemi Eleman Durumları	Amacı
R	Referans seviye belirleme	V1, V4, V5 Solenoit vanaları açık, pompalar açık Süresi: 100 s	Sensör haznesi ön temizlemeye tabi tutulur, Referans gerilim seviyesinin oluşması sağlanır.
KA	Koku Alma	V2, V3, V4 V5 Solenoit vanaları ve pompalar açık Süresi: 30 s	30 saniye boyunca örnek koku haznesinden 990 ml gaz e-burun tarafından içeriye çekilir.
SD	Sürekli Duruma Erişme	Tüm vanalar kapalı pompalar kapalı Süresi: 30 s	Sensörlerin sürekli duruma erişmesi sağlanmak için 30 saniye örnek koku, sensör haznesine hapsedilir.
KV	Koku Verme	V1, V4, V5 Solenoit vanaları açık, pompalar açık Süresi: 410 s	Sensör haznesi son temizlemeye maruz kalarak, örnek kokudan sensör haznesinin temizlenmesi sağlanır.

2.3. Kullanılan Veri Tabanları

Bu çalışma kapsamında önerilen yöntemler, 4 farklı veri tabanına uygulanmaktadır. Bu veri tabanlarından 3 tanesi bu çalışma kapsamında kurulan deney düzeneğiyle elde edilirken veri tabanlarından biri başka bir deney düzeneğinde elde edilen verileri içermektedir.

2.3.1. n-Butanol Gazına Ait Konsantrasyon Veri Tabanı (VERİ1)

Bu tez çalışmasında, e-burunla koku tanıma sistemini geliştirmek için donanım ve yazılım aşamalarında önerilerde bulunulmaktadır. Yazılım açısından önerilerin etkinliğini artırmak için önerilen yöntemin başka bir deney düzeneği ile elde edilen veri tabanına da uygulanmıştır. Böylece önerilen yöntemin başarısı sadece bu tez kapsamında kurulan e-burun deney düzeneğinden elde edilen verilerde değil, farklı e-burun kullanılarak elde edilen verilerde de kanıtlanmıştır. Bu amaçla n-butanol gazının 5 ile 20000 ppm arasında 20 farklı konsantrasyon değerlerini içeren veri tabanı kullanılmaktadır [136]. Uygulanan konsantrasyon değerleri sırasıyla, 5, 10, 25, 50, 100, 120, 240, 250, 480, 500, 960, 1000, 1940, 2500, 3880, 5000, 7750, 10000, 15550 ve 20000 ppm'dir.



Şekil 2.13. Alpha MOS Fox 3000 [137].

Bu veri tabanı 12 tane metal oksit sensör içeren, Şekil 2.13’de gösterilen ALPHA MOS Fox 3000 cihazıyla elde edilmiştir [137]. Elde edilen 80 koku örneğinden 60 tanesi eğitim verisi için kullanılırken kalan 20 koku verisi test için kullanılmaktadır. Bu çalışmanın geri kalanında bu veri tabanı VERİ1 olarak isimlendirilmektedir.

2.3.2. Birincil Kokulara Ait Veri Tabanı (VERİ2)

E-burun deney düzeneğini anlamak ve problemlerini daha rahat gözlemlemek adına; bu deney düzeneği ile ilk elde edilen veri tabanı basit bir problem olarak seçilmeye çalışıldı. Yani uygulanan ilk kokular birbirinden mümkün olduğunca uzak kokulardan seçildi. Bu çalışmada kurulan e-burun düzeneğine uygulanan kokuların birbirinden uzak olması amacıyla, ilk olarak birincil kokulara birer örnek olacak şekilde seçilmiştir. J. E. Amoore birincil kokuların 7’ye ayrıldığını savunmuştur [138]. Bu birincil kokular ve bunları içeren deney düzeneğine uygulanan örnek kokularla, her birincil kokuya ait örnek koku sayısı Tablo 2.6’da özetlenmektedir. Bu kokular elde edilirken test örnekleri farklı günlerde uygulanan birincil kokulardan elde edildi.

Tablo 2.6. Birincil kokuların oluşturduğu veri tabanı

Birincil Kokulara Örnek Kokular	Birincil Koku	E-Buruna Uygulanma Sayısı
Naftalin	Kafurlu	10
Melekotu Kökü	Misk	10
Gül	Çiçek	12
Nane	Nanemsi	10
Oje	Eterik	10
Limon	Keskin	8
Çürümüş Yumurta	Çürük	11
Yumurta	-	6
Sarımsak	-	10
Çimen	-	7
Aseton	-	10
Toplam veri sayısı		104

E-buruna 11 farklı koku uygulanarak, toplam 104 koku verisi elde edildi. Bunlardan 63 tanesi eğitim için kullanılırken, kalan 41 tanesi test için kullanılmaktadır. Bu çalışmada bu veri tabanı VERİ2 olarak isimlendirilmektedir.

Kokular için renklerin tümünü oluşturan ana renkler gibi temel kokulara sahip olup olmadığı çok tartışılmış ama her farklı alanın kendi içinde birincil kokulara sahip olduğunu savunanlar da bulunmaktadır [70, 138] . Burada J. E. Amoore'un birincil kokularından yararlanmanın amacı ise; gerçekten onların birincil kokular olduğunu savunmak değil, birbirinden uzak kokuları seçmekte bu ayırmadan yararlanmaktır. Şu göz ardı edilmemelidir ki, e-burun kokuyu, o kokuyu oluşturan molekülleri ayırt ederek değil, kokuyu bir bütün olarak ele aldığı tanımlanmaktadır. Dolayısıyla bu veri tabanında uygulanan kokular ortak moleküller içerebileceği gibi tamamen farklı molekülleri içerip aynı kokuyu verebilir. Koku örüntülerini tanımanın bir zorluğu da buradan gelmektedir.

2.3.3. Balık Kokularına Ait Veri Tabanı (VERİ3)

Çalışma kapsamında önerilen e-burun düzeneğinin ve örüntü tanıma yönteminin başarısının zor problemlerde nasıl olduğunu anlamak için, sınıflandırma problemi oldukça zor bir veri tabanına uygulanmıştır [125,139]. Bu amaçla, istavrit balığının tazeliğini tespit etmek için bir veri tabanı hazırlanmıştır. Balık tazeliğini tespit etmek amacıyla, deney düzeneğine balık satıcılarının (market) saklama koşullarındaki istavrit balığı uygulanmıştır.

Her uygulaniřta Karadeniz’de yakalanan orta byklkte bir balık, koku rnekleme haznesine yerleřtirilmiřtir. Eđitim ve test verisi farklı zamanlarda deney dzeneđine uygulanan balıklardan elde edilmektedir. Balıđın tazeliđinin tespit problemi, balıđın ka gnlk olduđunu belirlemeyle saptanmaktadır. Bu amala 1, 3, 5, 7, 9, 11 ve 13 gnlk, balıkı (market) ortamında saklanan balıklar deney dzeneđine uygulanmıřtır. Bu alıřmada sınıf sayısı, literatrde var olan alıřmalardan yksek tutularak daha zor bir problem haline getirilmiřtir. Ayrıca balıđın saklama kořulları literatrde var olan alıřmalara gre daha zorlařtırılarak deney dzeneđi ve rnt tanıma algoritmasının bařarısı sınanmıřtır. Literatrde balıklar +4 °C’de saklanırken, bu alıřmada +4 ° C ve belli aralıklarla buzlanmaya tabi olmuřtur [125, 139-143]. Buzlama iřleminin balıđın tazeliđini artırıcı bir etkisi bulunmaktadır. Bu kořullar altında dahi, birbirine yakın gnleri ayırıp ayırmadıđı tespit edilmektedir. Toplamda 185 koku elde edilmiřtir. Tablo 2.7’de bu veri tabanı iin kullanılan verilerin gnlere gre dađılımı verilmektedir.

Tablo 2.7. Balık tazeliđi testi iin kullanılan veri tabanının gnlere gre veri dađılımı

Sınıf (gnlk)	1	3	5	7	9	11	13	Toplam
Eđitim verisi sayısı	12	15	21	19	12	19	12	110
Test verisi sayısı	10	10	10	12	10	10	13	75
Toplam veri sayısı	22	25	31	31	22	29	25	185

Bunlardan 110 tanesi eđitim amalı kullanılırken, 75 tanesi ise test verisi olarak kullanılmaktadır. Test verisi farklı bir zamanda e-buruna uygulanan balıklarla elde edilmiřtir. Ayrıca bu alıřmada bu veri tabanı VERİ3 olarak isimlendirilmektedir.

2.3.4. Farklı Balık Kokularına Ait Veri Tabanı (VERİ4)

Son veri tabanı olarak deney dzeneđinin farklı balıkları algılayıp algılamadıđını anlamak iin, farklı gnlerde alınan 3 farklı balık tr deney dzeneđine uygulanmıřtır. Bu 3 farklı balık tr ise Karadeniz’de yakalanan istavrit, mezigit ve hamsi balıklarıdır. Farklı gnlerde toplam 129 deney yapılmıřtır. Bunlardan 50 veri test kmesi iin kullanılırken, 79 veri eđitim verisi olarak kullanılmaktadır.

Tablo 2.8. VERİ4 için eğitim ve test verilerinin dağılımı


	İstavrit	Hamsi	Mezgit	Toplam
Eğitim veri sayısı	27	27	25	79
Test veri sayısı	16	18	16	50
Toplam veri sayısı	43	45	41	129

Balıkçının saklama koşullarında depolanan balıklarla deneyler yapılmıştır. Bu veri tabanındaki eğitim ve test verilerinin dağılımı Tablo 2.8’de gösterilmektedir. Bu veri tabanı VERİ4 olarak isimlendirilmektedir.

2.4. İşaret Ön İşleme

Gaz sensörlerinin en büyük sorunlarından biri sensör cevaplarında meydana gelen kısa dönem ve uzun dönem kaymalardır. Özellikle ölçümlerin sık olmasından kaynaklanan sensörlerin hafıza etkisi kısa dönem kaymalara sebep olurken, sensör zehirlenmeleri ve yaşlanmaları uzun dönem kaymalarına neden olur. Bu ve benzeri sebeplerden dolayı işaret ön işleme aşaması ayrı bir önem kazanmaktadır. İşaret ön işleme aşaması sayesinde problemin boyutu indirgenirken, işaretin gürültü ve sensör kayması problemlerinden etkilenmesi de azaltılmaktadır. Bu sayede örüntü tanıma başarısının artması sağlanır.

Bu çalışma kapsamında kurulan deney düzeneğiyle elde edilen tüm verilere, işaret ön işleme Şekil 2.14’de gösterildiği gibi uygulanmaktadır. Aynı zamanda; uygulanan işaretin ön işlemeye göre sınıflandırma başarısının nasıl değiştiği bulgular ve irdeleme kısmında gözlemlenmektedir.



Şekil 2.14. İşaret işleme aşamaları

Bir veri kümesi varsayalım ki N_0 adet örnekten oluşmaktadır. Her örnek için $s=1 \dots N_s$ adet sensörden veri alınmaktadır. Her sensörden $k=1 \dots N_k$ adet örnek alınmış olduğu kabul edilsin. Bu çalışmada kullanılan veri tabanları için örnek sayısı, sensör sayısı ve kaç adet örnek alındığı Tablo 2.9’da özetlenmektedir.

Tablo 2.9. Veri tabanları veri dağılımı

Veri Tabanı	Örnek koku Sayısı	Sensör Sayısı	1 Veri İçin Elde Edilen Toplam Örnek Sayısı	Sınıf Sayısı
VERİ1	80	12	1	20
VERİ2	104	8	600	11
VERİ3	185	8	600	7
VERİ4	129	8	600	3

İşaret ön işleme biriminde koku örüntüsünü tanımda en çok kullanılan aşamalar referans düzeltme (referans manipülasyonu), sıkıştırma ve normalize etme aşamalarıdır [92]. Bu ön işleme aşamalarının sırası sabit değildir. Kimi çalışmalarda normalizasyon sıkıştırma işleminden önce uygulanırken, kimi çalışmalarda sonra uygulanmaktadır. Bu tez kapsamında kullanılan işaret ön işleme aşamaları aşağıdaki bölümde detaylıca incelenmektedir.

2.4.1. Referans Gazın Çıkartılması

Bu tez çalışmasındaki VERİ2, VERİ3 ve VERİ4'e, işaret ön işlemenin ilk aşaması olarak referans gazın çıkartılması uygulanmaktadır. İşaret ön işleme sayesinde problemin boyutu indirgenirken, işaretin gürültü ve sensör kayması problemlerinden arındırılmasına çalışılmıştır. Sensör cevabının kayması kullanılan metal oksit sensörlerde meydana gelen en büyük problemlerden biridir [117]. Bu problemi aşmak adına literatürde kullanılan referans düzeltme (baseline manipulation) [92] yanında, literatürde uygulanmamış bir yöntem uygulanmaktadır. Aynı zamanda ortamın ve taşıyıcı gazın sensörler üzerindeki olumsuz etkileri de azaltılmaya çalışılmıştır. Bu yöntemin çıkış noktası aynı anda iki tane e-burun kullanarak sensor kaymalarını azaltan çalışmadır [144]. Bu çalışmaya göre; kokuyu taşıyan gaz ile örnek kokuyu, aynı anda birbirinin aynı olan iki e-burundan geçirip, iki işaretin farkını örüntü tanıma kısmına uygulayarak sistemin başarısı artırılmaktadır. Bu çalışmada ise aynı e-burun kullanılarak, daha basit ve maliyeti ucuz bir sistemle sensör kaymalarından meydana gelen problem azaltıldı. Bunu yapmak için deney düzeneğine her gün düzenli olarak taşıyıcı gaz ortalama 3 kere, tıpkı koku örneği gibi örneklenecek koku olmadan uygulandı. Her gün alınan taşıyıcı gaz işaretlerinin ortalaması, o güne ait elde edilen örnek koku işaretlerinden çıkartılarak, işaret ön işlemenin diğer aşamalarına ve

örüntü tanıma sistemine bu fark işareti uygulandı. Fark işareti (2.1) bağıntısındaki gibi ifade edilebilir.

$$V_{n,s}^F(t) = V_{n,s}(t) - V_{t,s}(t) \quad (2.1)$$

(2.1) bağıntısında $V_{n,s}$ n. örnek koku için s. sensörden elde edilen gerilim işareti, $V_{t,s}$ taşıyıcı gaz için s. sensörden elde edilen gerilim işareti ve $V_{n,s}^F(t)$ ise işaret işlemeye gönderilecek s. sensör için elde edilen fark gerilimidir. Fark işaretinin uygulanmasıyla, örnek koku haznesinin ve taşıyıcı gazın sensörlere olumsuz etkisinin azaltıldığı bulgular ve irdeme kısmında gösterilen sensör işaretlerinden gözlemlenmektedir.

2.4.2. Referans Düzeltme

Referans düzeltme işaret ön işleme evrelerinden biridir. Bu sayede sensör sapmalarının önüne geçilmektedir [136]. En yaygın kullanılan referans düzeltme bağıntıları genel bilgiler kısmında verilmektedir. Bu tez çalışmasında fark referans düzeltme yöntemi uygulanmıştır.

Referans gazın sensör işaretinden çıkartılmasıyla elde edilen fark gerilimine, daha sonra (2.2) bağıntısındaki gibi referans düzeltme uygulanmıştır.

$$V_{n,s}^R(t) = V_{n,s}^F(t) - V_{n,s}^F(0) \quad (2.2)$$

(2.2) bağıntısında $V_{n,s}^F(0)$ ilk örneklemede elde edilen işareti temsil ederken, $V_{n,s}^R(t)$ ise referans düzeltmeye maruz kalan fark gerilimini göstermektedir. Bu elde edilen işaret çıkış direncinin üzerindeki gerilim değişimidir. Genellikle sensör direnci veya iletkenliği kullanılmaktadır [108]. Bu çalışmada sensör iletkenliği kullanılmıştır. Dolayısıyla yük direnci gerilim değerlerinden yararlanarak, işaret ön işleme kısmında sensörlerin iletkenliklerinin gazla değişimi (2.3) bağıntısındaki gibi elde edilmiştir.

$$G_{n,s}^R(t) = \frac{V_{n,s}^R}{(V_c - V_{n,s}^R)R_{L,s}} \quad (2.3)$$

(2.3) bağıntısındaki $G_{n,s}^R(t)$ n. örnek koku için s. sensörün işaret ön işlemeye uygulanan iletkenlik cevabı olarak alınırken, V_c sensörün besleme gerilimi, $R_{L,s}$ s. sensörün yük direnci olarak alınmıştır.

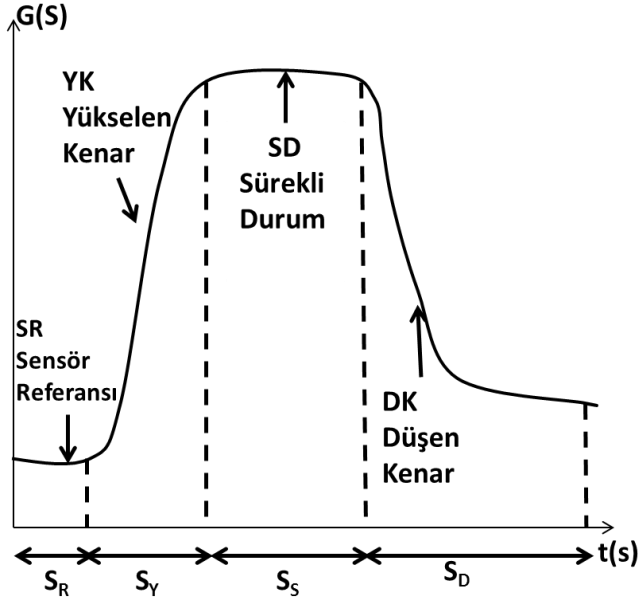
2.4.3. Öznitelik Çıkarma

Öznitelik çıkarma her örnekten ölçülen veri sayısını azaltmak için, sensör cevaplarından genel tanımlayıcı parametreler çıkartma işlemidir. En iyi öznitelik çıkarma yöntemi problemin doğasına ve kullanılan sensöre göre değişir [145]. Bu yüzden e-burun uygulamaları için en iyi öznitelik çıkarma yöntemi hakkında genelleme yapmak çok zordur.

Literatürde öznitelik çıkarmada birçok yöntem kullanılmıştır [94-109, 146]. E-burun uygulamalarında öznitelik çıkarma yöntemleri 3 ana başlık altında toplanmaktadır [92]. Genel bilgiler kısmında değinilen bu yöntemlerden, alt örnekleme yöntemi ve parametre çıkarma yöntemleri bu çalışma kapsamında veri tabanlarına uygulanarak karşılaştırma yapılmasına olanak sağlanmaktadır. Uygulanan yöntemlerin detayları aşağıdaki bölümlerde incelenmektedir.

2.4.3.1. Öznitelik Olarak Parametre Çıkartma Yaklaşımı

Gaz sensörleri cevabından parametre çıkarımı elde edilirken sürekli durum parametrelerinden veya geçici durum parametrelerinden yararlanılır. Sürekli durum parametrelerinden yararlanmak için deney sürelerinin buna göre ayarlanması gerekir. Literatürde iki farklı koku örnekleme süresi üzerinde durulmuştur. Buradaki fark, kokunun sensör haznesine uygulanma süresidir. Sürekli durum değeri önem arz etmekte ise, sensör haznesine uygulanma süresi daha uzun tutulurken; sadece geçici durum değerlerinden parametreler belirlenecekse bu süre kısaltılır. İki ölçümün de birbirine göre avantajları ve dezavantajları vardır. En doğru sonucu veren yöntem kullanılan sensöre ve kokunun türüne göre değişim göstermektedir. Sensör işaretinin herhangi bir örnek kokuya cevabının geçiş bölgeleri Şekil 2.15'deki gibi isimlendirilmektedir. Bu geçiş bölgelerinin sayısal tanımı Tablo 2.10'da özetlenmektedir.



Şekil 2.15. Örnek bir sensör işareti

Tablo 2.10. Örnek sensör işareti için bölgeler

Kısaltma	Bölge Adı	Başlangıç Örneği	Bitiş Örneği
SR	Sensör Referansı	0	S_R
YK	Yükselen Kenar	S_R+1	S_R+S_Y
SD	Sürekli Durum	S_R+S_Y+1	$S_R+S_Y+S_S$
DK	Düşen Kenar	$S_R+S_Y+S_S+1$	$S_R+S_Y+S_S+S_D$

Bu çalışmadaki VERİ2, VERİ3 ve VERİ4 için kullanılan parametre çıkarma yöntemleri Tablo 2.11’de özetlenmektedir.

Parametre çıkartma yöntemlerinden en sık kullanılanı sürekli durum değerinin parametre olarak alınmasıdır. Sürekli durum değerinin belirlenmesine kullanılan yöntemlerden biri, sensör cevabı sürekli durumdayken alınan örneklerin ortalamasının (2.4) bağıntısındaki gibi alınmasıdır. Diğeri ise sensör cevabının maksimum değerinin (2.5) bağıntısındaki gibi öznitelik olarak belirlenmesidir.

$$\bar{O}(n,m) = \frac{1}{S_{SD}} \sum_{k=a}^{k=b} G_{n,s}^R[k] \quad a = S_R + S_Y + 1 \quad b = S_R + S_Y + S_S \quad (2.4)$$

$$\bar{O}(n,m) = \text{maksimum} (G_{n,s}^R[k]) \quad (2.5)$$

Tablo 2.11. Kullanılan parametre çıkarma yöntemleri

Parametre numarası	Parametre adı
1	Maksimum değeri
2	Maksimuma ulaşma süresi
3	Yükselen kenarda maksimumun %60'ına ulaşma süresi
4	Yükselen kenarda maksimumun %90'nına ulaşma süresi
5	Düşen kenarda maksimumun %90'ına ulaşma süresi
6	Düşen kenarda maksimumun %60'ına ulaşma süresi
7	Yükselen kenar 3 eşit parçaya bölündüğünde ilk parçanın türevi
8	Yükselen kenar 3 eşit parçaya bölündüğünde ikinci parçanın türevi
9	Yükselen kenar 3 eşit parçaya bölündüğünde üçüncü parçanın türevi
10	Düşen kenar 3 eşit parçaya bölündüğünde birinci parçanın türevi
11	Düşen kenar 3 eşit parçaya bölündüğünde ikinci parçanın türevi
12	Düşen kenar 3 eşit parçaya bölündüğünde üçüncü parçanın türevi
13	Ortalaması
14	Standart Sapması
15	Çarpıklık katsayısı
16	Basıklık katsayısı
17	Yükselen kenarın integrali
18	Düşen kenarın integrali

Geçici durum yöntemlerinden biri olan zaman sabiti yönteminde parametre olarak, işaretin yükselen ve düşen kenarlarında maksimum değerini belli bir yüzdesine ulaşmasına kadar geçen süre (2.6) bağıntısındaki gibi alınır [136].

$$T_{on}Y = Arg_{a < k < b} \left(\left(\frac{Y}{100} \text{maksimum}(G^{R}_{n,s}[h]) - G^{R}_{n,s}[k] \right) = 0 \right) \quad \forall n, s \quad (2.6)$$

Burada $T_{on}Y$ yükselen kenarda maksimum değerini % Y 'sine kadar geçen süre olarak alınır. Bu çalışmada $Y=60$ ve $Y=90$ değerleri parametre olarak alındı. Yine (2.6) bağıntısında a kokunun uygulanmaya başladığı zamanı gösterirken ($a=S_R+1$), b ise maksimum değere ulaştığı zamanı gösterir.

$$T_{off}Y = Arg_k \left(\left(\frac{Y}{100} \text{maksimum}(G^{R}_{n,s}[h]) - G^{R}_{n,s}[k] \right) = 0 \right) \quad \forall n, s \quad (2.7)$$

(2.7) ifadesinde $T_{off}Y$ düşen kenarda maksimum değerin % Y 'sine kadar geçen süre olarak alınır. Arg fonksiyonu ise geçen süreyi hesaplayan fonksiyondur.

Geçici durum yöntemlerinden olan geçici durumdaki işaretin türevlerinin ortalama değerlerinin parametre olarak alınması da e-burun uygulamalarında sıklıkla kullanılmaktadır [93]. Bu yöntemde ilk olarak türevi alınacak kısım yükselen kenar veya düşen kenar şeklinde ikiye ayrılır. Yükselen ve düşen kenarda kendi içinde eşit parçalara ayrılır. Bu çalışmada her iki kenar da 3 eşit parçaya ayrılmaktadır. Her parçanın kendi içinde türevi alınıp, bu türevlerin toplanıp, kullanılan örnek sayısına bölünmesiyle (2.8) ve (2.9)'da belirtildiği gibi parametre elde edilmektedir.

$$G^{R'}_{n,s}[k] = \frac{G^{R}_{n,s}[k+1] - G^{R}_{n,s}[k]}{k+1-k} = G^{R}_{e,s}[k+1] - G^{R}_{e,s}[k] \quad \forall n,s \quad (2.8)$$

$$X^h_{e,s}[k] = \frac{1}{k_n} \sum G^{R'}_{n,s}[k] \quad \forall n,s \quad (2.9)$$

(2.9) ifadesindeki k_n her bölünmüş parçadaki örnek sayısıdır.

İşaretin ortalaması ve standart sapması da işaret hakkında bilgi taşımaktadır. Parametre olarak çıkartılan ortalama ve standart sapma sırasıyla (2.10) ve (2.11) ifadelerindeki gibi elde edilir.

$$\overline{G_{n,s}} = \frac{1}{k_n} \sum_{k=1}^{k_n} G^{R}_{n,s}[k] \quad (2.10)$$

$$\sigma = \sqrt{\frac{1}{k_n} \sum_{k=1}^{k_n} (G^{R}_{n,s}[k] - \overline{G_{n,s}})^2} \quad (2.11)$$

Çarpıklık (skewness) ve basıklık (kurtosis) katsayısı olarak adlandırılan parametreler sensörlerin dinamik cevabını tanımlayan parametrelerdir [102]. Çarpıklık ve basıklık sırasıyla (2.12) ve (2.13) ifadesindeki gibi elde edilir.

$$\gamma_1 = \frac{\frac{1}{k_n} \sum_{k=1}^{k_n} (G^{R_{n,s}}[k] - \overline{G_{n,s}})^3}{\sigma^3} \quad \forall n, s \quad (2.12)$$

$$g = \frac{\frac{1}{k_n} \sum_{k=1}^{k_n} (G^{R_{n,s}}[k] - \overline{G_{n,s}})^4}{\sigma^4} - 3 \quad \forall n, s \quad (2.13)$$

Dinamik cevap parametrelerinden olan yükselen ve düşen kenarın (2.14) ifadesindeki gibi integralinin parametre olarak alınması diğer bir öznitelik çıkarma yöntemidir.

$$I_{n,s}^h[k] = \sum_{k=a}^b G^{R_{n,s}}[k] \Delta k \quad \forall n, s \quad (2.14)$$

(2.14) bağıntısında I^h işaretin h bölgesinin integralini ifade etmektedir.

2.4.3.2. Alt Örneklemeye Yöntemi ile Öznitelik Çıkarma Yaklaşımı

Alt örneklemeye metodu için sensör cevaplarından farklı aralıkta örnekler alınmakta ve sisteme uygulanmaktadır. Alt örneklemeye metodunda n . koku örneği ve s . sensörde seçilen örnekler W olmak üzere (2.15) bağıntısıyla hesaplanır. Bu bağıntıda t bir sensör için seçilen parametre sayısını ifade ederken, k_t örneklemeye aralığını temsil eder.

$$W_{n,s}^i = G^{R_{n,s}}[i.k_t] \quad i = 1, \dots, t \quad k_t = 600/t \quad (2.15)$$

Bir koku örneği için bir sensörden k_t aralıklarla t adet parametre belirlenmektedir. Bu çalışmada farklı örneklemeye aralıkları seçilmiştir. Bu örneklemeye aralıklarının belirlenmesi çapraz doğrulama yöntemiyle yapılmaktadır. Bunlardan en çok kullanılanı örneklemeye aralığını 60 belirleyerek bir sensörden 10 parametre çıkartılmasıdır. Bu çalışmada veri tabanları için kullanılan örneklemeye aralıkları, bir sensörden çıkartılan parametre sayısı ve bir koku örneğinin temsili için seçilen parametre sayısı Tablo 2.12'de gösterilmektedir.

Tablo 2.12. Farklı veri tabanlarında alt örnekleme öznitelik çıkarma yöntemi parametreleri

Veri Tabanı	Örnekleme Aralığı	Parametre Sayısı	Bir Koku Örneği İçin Elde Edilen Öznitelik Sayısı
VERİ2	60	10	80
VERİ3	60	10	80
VERİ4	75	7	56

2.4.4. Normalizasyon

Normalizasyonun temel amacı verileri genel veriler içinde ağırlıklandırarak verilerin kolay yorumlanmasını sağlamaktır [113]. Öznitelik çıkartma işleminde, farklı öznitelikler öznitelik vektörü içinde toplanabilir. Mesela yükselme zamanı ile iletkenliğin maksimum olduğu değerler aynı öznitelik vektöründeyken birbirleriyle karşılaştırılmazlar. Bu yüzden yeni bir ölçeklendirmeye ihtiyaç duyarlar. Bu yüzden normalizasyon uygulanmaktadır.

Bu tez çalışması kapsamında (2.16) bağıntısıyla verilen 0 ile 1 arası ölçeklemeyi sağlayan yöntem kullanılmaktadır. $\ddot{O}(n,m)$, m. koku örneği için n adet öznitelik vektörünü göstermektedir.

$$Z(n,m) = (\ddot{O}(n,m) - \min(\ddot{O}(n,m))) / (\max(\ddot{O}(n,m)) - \min(\ddot{O}(n,m))) \quad (2.16)$$

2.4.5. Öznitelik Seçme

Giriş bölümünde anlatıldığı üzere, önceden belirlenmiş öznitelik kümesinden sınıfları daha iyi ayırt edici özniteliklerin seçilme işlemi sınıflandırıcı başarısını artırırken, boyutun daha da düşürülmesiyle sınıflandırma işlem yükünü de azaltmış olur [112]. Aynı zamanda örüntü tanıma başarısını olumsuz etkilememek adına, bir veri tabanındaki sınıf sayısı, kullanılan öznitelik sayısının ve veri tabanındaki örnek sayısı belirli bir oranda olması gerektiği ile ilgili ön kabuller literatürde mevcuttur [147,148]. Bir sınıf içindeki veri sayısının, o sınıfı ayırt etmek için kullanılan öznitelik sayısına oranının 10 katından fazla olması gerektiği (2.17) ifadesindeki eşitlikle savunulmakta [148], ama bazı pratik uygulamalarda bu mümkün olmayacağından bunun (2.18) ifadesindeki gibi 5 katından büyük olmasının yeterli olacağı belirlendi [147,149].

$$\frac{S_n}{S_{\delta} \times r} > 10 \quad (2.17)$$

$$\frac{S_n}{S_{\delta} \times r} > 5 \quad (2.18)$$

(2.17) ve (2.18) ifadesindeki S_n tüm sınıflarda kullanılan toplam örnek sayısını, r sınıf sayısını ve S_{δ} kullanılan öznitelik sayısını vermektedir. Bu tez çalışmasında (2.18) ifadesindeki ön kabulü bazı veri tabanlarında sağlamak mümkünken, bazı veritabanlarında örnek sayısından dolayı sağlanamamaktadır.

Çeşitli uygulamalarda birçok farklı öznitelik seçme algoritması kullanılmaktadır [108,145]. Bunların arasından; en iyi öznitelik alt kümesini kesin sonuçla bulan, tam kapsamlı arama algoritması mevcuttur. Bu algoritma tüm öznitelik alt küme kombinasyonlarını deneyerek sonuca ulaşmaktadır. Fakat bu algoritma öznitelik sayısı fazla olan uygulamalarda hesap yükünden dolayı tercih edilmemektedir. Bu çalışmada aşağıdan yukarıya doğru çalışan ardışık ileri yönde seçim yöntemi, öznitelik alt küme seçiminde uygulanmaktadır [112]. Koku örnekleri fazla sayıda öznitelikle temsil edildiğinde hesap yükünü azaltmak için kullanılan bir yöntemdir. Bu yöntemde, seçilecek öznitelik kümesine her adımda bir öznitelik eklenir. Bu işlem istenen öznitelik sayısına ulaşıncaya veya belli bir başarıya ulaşıncaya sonlandırılır. Burada kriter olarak öznitelik eklendiğindeki sınıflandırıcı başarısındaki değişim durma noktasına veya düşme noktasına gelinceye kadar devam ettirilir. Bazı sınıflandırıcılarda 2 öznitelikle yüksek başarı elde edilirken, bazı sınıflandırıcılarda daha fazla sayıda öznitelikle aynı başarının sağlandığı tespit edildi. Buradan anlaşılacağı üzere örüntü tanıma başarısı, çıkarılan özniteliklerle ve sınıflandırıcının yapısıyla değişkenlik göstermektedir.

2.5. Sınıflandırma

Sınıflandırma, çıkarılan özniteliklerin formüle edildiği, özniteliklerle modeller oluşturup, tanımlayıcı kararların alındığı aşamadır. Çıkarılan özniteliklerden örüntünün hangi sınıfa ait olacağını belirleyen birimdir. Tasarlanacak sınıflandırıcının amacı farklı sınıflara ait uzayı bölecek yüzeyler bulmaktır. Gerçek hayattaki çoğu sınıflandırma probleminde sınıfları ayıracak yüzeyler doğrusal olmamaktadır. Başarılı sınıflandırıcı

tasarlamak için probleme ne çeşit bir doğrusal olmayan dönüşümün adapte edileceğini belirlemek ve ne çeşit optimizasyon kriterinin kullanılacağını doğru tespit etmek gerekir [122]. Bunların belirlenmesi probleminden probleme değişmektedir.

2.5.1. Bayes Sınıflandırma Algoritması

İstatistiksel yaklaşımların başında gelen Bayes teoremine dayalı Bayes sınıflandırıcı örüntü tanıma problemlerinde sıklıkla kullanılmaktadır [122]. Bu sınıflandırıcının kullanım alanını sınırlayan ve en önemli dezavantajı özniteliklerin istatistiksel açıdan birbirinden bağımsız olduğu varsayımını kullanmasıdır. Buna karşın ilintisiz özniteliklere karşı hassasiyeti yoktur. İlintisiz öznitelikler olasılık sonucunu büyük oranda etkilemezler. Özniteliklerin ilintisiz seçilmesi durumunda verinin bir sınıfta olma olasılığı diğer sınıfta olma olasılığına çok yakın çıkmakta ve verinin hangi sınıfa ait olduğunu ayırt etmekte başarılı sonuçlar vermemektedir.

Bir olayın gerçekleşmesi bazı koşulların oluşmasına bağlı ise koşullu olasılıktan söz edilir[123]. B olayının gerçekleşmesi A olayının gerçekleşmesine bağlıdır. Bu durum $P(B|A)$ şeklinde gösterilir ve (2.19) eşitliğindeki gibi ifade edilir.

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)} \quad (2.19)$$

Sade Bayes Sınıflandırıcısında $X = \{x_1, x_2, \dots, x_n\}$ sınıf üyeliği bilinmeyen veri örneği olsun. Bu örnek sınıfta m sınıf olsun. C_1, C_2, \dots, C_m sınıf değerleri olsun. Böylece veri örneğinin m koşullu olasılığı ortaya çıkmaktadır. Öncelikle x özniteliklerinin sınıflara göre olasılıkları $P(x_k/C_i)$ hesaplanır. x_k değerlerinin birbirinden bağımsız olduğu kabul edilerek (2.20) bağıntısı kullanılabilir.

$$P(X|C_i) = \prod_{k=1}^n P(x_k|C_i) \quad (2.20)$$

Bilinmeyen örnek X'i sınıflandırmak için X'in m sınıfta olma olasılıkları (2.21) bağıntısıyla hesaplanır. (2.21) bağıntısında paydalar eşit olduğundan paylar karşılaştırılır

ve X 'in hangi sınıfta olma olasılığı en büyük olma durumuna göre sınıflandırma sonucuna karar verilir.

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \quad (2.21)$$

En büyük sonrasal sınıflandırma yöntemi (Maximum A Posteriori classification-MAP) kullanılarak Bayes sınıflandırıcı (2.22) nolu bağıntıdaki gibi de ifade edilebilir [123].

$$C_{MAP} = \arg \max_{C_i} \prod_{k=1}^n P(x_k|C_i) \quad (2.22)$$

Bayes sınıflandırıcılarda x_k niteliklerinin C_i sınıfında olma olasılıklarından biri sıfır çarpım sonucu tüm genel olasılık değeri de sıfır çıkacaktır. Bu da diğer olasılıkların etkisini yok edip sonuçta hataya neden olacaktır. Bunu önlemek için k gibi küçük bir değer (2.23) ifadesindeki gibi oranlara eklenebilir.

$$\frac{pay + kp}{payda + k} \quad (2.23)$$

Burada k , 0 ile 1 arasında bir sayıdır, genellikle 1 alınır. p ise bir özniteliğin, kaç sınıf değeri varsa ona orantısıdır. İki sınıf varsa $1/2$ den $p=0.5$ olur.

Nitelik değerleri sayısal ise, sayısal verilerin dağılımının normal dağılım olduğu varsayılarak genellikle (2.24)'de gösterilen olasılık yoğunluk fonksiyonu kullanılır. (2.28) eşitliğinde μ_c ortalama, σ_c ise standart sapmadır.

$$P(x_k|C_i) = f(x_k, \mu_c, \sigma_c) = \frac{1}{\sqrt{2\pi\sigma_c}} e^{-\frac{(x_k - \mu_c)^2}{2\sigma_c^2}} \quad (2.24)$$

Çoğunlukla Gaussian dağılım fonksiyonunun kullanılmasının sebebi ise hesaplamalarının izlenebilirliği ve modeli çoğu durumu kapsayabilecek genel bir ifade olmasıdır [151].

2.5.2. Doğrusal Ayırma Analizi Algoritması

Örüntü tanıma algoritmalarında sık kullanılan istatistiksel yöntemlerden bir diğeri de ayırma analizidir. Ayırma analizi ortak özellikleri birbiri içine girmiş grupları ayırmak için grup ortalama vektörlerini ayıran fonksiyonlar üretir [122]. Doğrusal Ayırma Analizinde verinin düzgün dağılımlı olduğu varsayılır. Ayırma analizinin hedefi, sınıflar arası mesafeyi maksimum, sınıf içi mesafeyi minimum yapmaktır. Böylece sınıfların maksimum ayrılabilirliğini garanti eder [150]. İki farklı yaklaşımı kullanarak verileri başka bir uzaya transfer eder [151]. Bunlardan biri sınıf bağımlı dönüşüm, diğeri de sınıf bağımsız dönüşümdür. Sınıf bağımlı dönüşümde, amaç fonksiyonu sınıflar arası kovaryans matrisinin sınıf içi varyansa oranını maksimize ederken, sınıf bağımsız dönüşümde ise amaç fonksiyonu tüm verinin varyansının sınıf içi varyansa oranını maksimize etmektedir [152]. Sınıf bağımsız dönüşümde amaç o sınıfı diğer sınıfların hepsine karşı ayrılabilir hale getirmektir. Ayırma analizi adımları aşağıdaki gibi özetlenebilir [122].

Adım 1: Verileri sınıflarına göre ayırıp her i . sınıfın kendi ortalaması μ_i alınıp yine aynı veri matrisinden çıkarılırsa $(x - \mu_i)$ ortalaması sıfır olan matris elde edilir.

Adım 2: Her sınıfa ait kovaryans matrisler hesaplanır. Her sınıfa ait kendi içinde veri dağılımını gösteren kovaryans matrisler m adet sınıfa ait S_i matrisleri ve bunların toplamı olan S_w matrisi hesaplanır. Burada n_i i . sınıfa ait veri sayısı iken μ_i i . sınıfa ait ortalama değeri ifade etmektedir.

Adım 3: Her grubun ortaya çıkma olasılığı $p_i = n_i/N$ tüm sınıflar için hesaplanır.

Adım 4: Tüm sınıflar için ayırma fonksiyonu (2.25) ifadesindeki gibi hesaplanır. (2.29) ifadesindeki μ_i i . sınıfa ait verilerin ortalama değeri, C i . sınıfa ait kovaryans matrisidir.

$$f_i = \mu_i C^{-1} x_k^T - \frac{1}{2} \mu_i C^{-1} \mu_i^T + \ln(p_i) \quad (2.25)$$


Adım 5: Sınıflandırılması istenen veri, grupları ayıran fonksiyonlardan hangisinde maksimum sonucu veriyorsa verinin o gruba ait olduğu kabul edilir.

Bu çalışmada kullanılan algoritma sınıf bağımlı algoritmadır. Sınıflar arası varyansın, sınıf içi varyansa oranı dikkate alınmaktadır.

2.5.3. Destek Vektör Makinası Algoritması

Son yıllarda uygulama alanı genişleyen ve bu çalışmada da kullanılan DVM Vapnik tarafından ilk olarak doğrusal sınıflandırıcı olarak geliştirildi [148,149]. DVM sınıflandırmayı doğrusal veya doğrusal olmayan bir fonksiyon yardımıyla yerine getirirken, veriyi birbirinden ayırmak için en uygun fonksiyonun tahmin edilmesi esasına dayanır [1]. Doğrusal ayrılamayan problemlerde n boyutlu veri kümesi $m > n$ olacak şekilde m boyutlu veri kümesine dönüştürülür. Yüksek boyutta dönüştürme işlemi yapılır. Ayıran hiper düzleme en yakın öğrenme verileri destek vektörleri olarak adlandırılırlar.

Doğrusal olarak birbirinden ayrılabilen Şekil 2.16'daki örneği verebiliriz. İki boyutlu uzay için düşünürsek veriyi birbirinden farklı birçok doğrunun ayıracağı şekilde gözükmemektedir. Çok boyutlu uzayda bu doğruların yerini hiper düzlemler almaktadır. Buradaki temel sorun verileri birbirinden ayıracak en uygun doğrunun seçilmesidir.



Şekil 2.16. Doğrusal ayrılabilen veri görünümü [149].

Şekil 2.16'da iki veri grubunu ayıran iki farklı yönde düzlem gösterilmektedir. Bu iki doğrudan destek vektörleri arasındaki en büyük boşluğu 1. yöndeki düzlemin oluşturduğu Şekil 2.16'dan anlaşılmaktadır [149]. Bu yöntemde en uygun düzlem, arasında en büyük boşluk bulunan iki hiper düzlemin ortasından geçen hiper düzlemdir. Şekil 2.16'da en büyük boşluk H_1 düzlemi ile H_2 düzlemi arasında olduğu görülmektedir. Buna göre H_0 düzlemi de bu iki hiper düzlemin arasından geçen en uygun ayırma hiper düzlemi olarak

adlandırılır. H_0 düzlemi üzerindeki noktalar cinsinden (2.26) bağıntısındaki gibi ifade edilir.

$$H_0 : W^T X + b = 0 \quad (2.26)$$

Burada W ağırlık vektörünü, X ise öznelikleri belirtirken b sabit sayıdır. (2.26) nolu ifade (2.27)'deki gibi ifade edilebilir.

$$\sum_{i=1}^n w_i x_i + b = 0 \quad (2.27)$$

n öznelik sayısını vermektedir. H_1 ve H_2 düzlemleri üzerindeki yuvarlak içinde olan gözlemler destek vektör adını alır. En büyük boşluk m olarak ifade edilirse bağıntısı (2.28)'deki gibidir.

$$m = 2d = \frac{2}{\|w\|} = \frac{2}{\sqrt{w_1^2 + w_2^2 + \dots + w_n^2}} \quad (2.28)$$

Amaç H_1 ve H_2 düzlemleri arasındaki boşluğu optimize etmek olduğu için, $\|w\|$ ifadesinin minimizasyonu m 'yi maksimize edecektir. Bu tür problemleri çözmek için Lagrange fonksiyonlarından yararlanılabilir.

$$L(w, b, \lambda) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \lambda_i (y_i (w^T x_i + b) - 1) \quad (2.29)$$

(2.29) bağıntısında λ Lagrange çarpanlarının vektörü olmak üzere, $L(w, b, \lambda)$ Lagrange fonksiyonunu ifade etmektedir. Lagrange fonksiyonunun kısmi türevi (2.30) ve (2.31) ifadelerindeki gibi alınarak kritik noktalar hesaplanır.

$$\frac{\partial}{\partial w} L(w, b, \lambda) = 0 \quad (2.30)$$

$$\frac{\partial}{\partial b} L(w, b, \lambda) = 0 \quad (2.31)$$

(2.29), (2.30) ve (2.31) ifadeleri birleştirildiğinde (2.32) ve (2.33) sonuçları elde edilir.

$$w = \sum_{i=1}^N \lambda_i y_i x_i \quad (2.32)$$

$$\sum_{i=1}^N \lambda_i y_i = 0 \quad (2.33)$$

Elde edilen (2.32) ve (2.33), (2.29)'da yerleştirilir ve gerekli sadeleştirmeler yapılırsa (2.34) bağıntısı elde edilir. Bu ifadeyle amaç sadece λ 'nın optimizasyonuna dönüşmektedir ki, bu da optimizasyon problemini kolaylaştırmaktadır.

$$L(w, b, \lambda) = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j x_i^T x_j \quad (2.34)$$

Sıfırdan farklı Lagrange çarpanlarına sahip olması için, x_i noktalarının hata eşitliğini sağlaması gerekmektedir. Bu noktalar da Destek Vektörleri adını alırlar.

Verilerin doğrusal olarak ayrılması mümkün değilse, ilk önce gevşek değişkenler ξ ile ifade edilen doğrusal ayrılmayı önleyen değişkenlerinde optimizasyon modeline eklenmesiyle soruna çözüm aranır. Gevşek değişkenler kısıtlardaki sapmaları ölçerler. En büyük boşluk mesafesi maksimize edilerek, kısıtlardaki sapma oranına denk düşen bir ceza parametresi belirlenir. Problemin yeni tanımı (2.35) ve (2.36)'ya dönüşür.

$$y_i [\langle w, x_i \rangle + b] \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad i = 1, \dots, n \quad (2.35)$$

olmak koşuluyla,

$$J(w) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (2.36)$$

Denkleminin minimizasyonu amaç fonksiyonuna dönüşür. C, ceza parametresi yanlış sınıflandırma hatasını ayarlamak için kullanılan parametredir ve kullanıcı tarafından belirlenir. Bu çalışmada, ceza parametresi olan C çapraz doğrulama yöntemiyle belirlenir. Yukarıda anlatılan soruna, gevşek değişken modeliyle elde edilen çözüm yerine doğrusal olmayan sınıflandırıcı kullanarak da çözüm getirilebilir. Mesela iki boyutlu verileri üç boyutlu verilere ϕ çekirdek fonksiyonu yardımıyla çevirerek bir hiper düzlemle ayırabilme olanağı sağlanabilir.

İki boyutlu bir özellik uzayında $x=[x_1, x_2]$ vektörünü özellik uzayındaki $z(x) = [\phi_1(x), \dots, \phi_6(x)]$ vektörüne dönüştürmek için ϕ ifadeleri (2.37)-(2.42) bağıntısındaki gibi seçilebilir.

$$\phi_1(x) = 1 \quad (2.37)$$

$$\phi_2(x) = \sqrt{2}x_1 \quad (2.38)$$

$$\phi_3(x) = \sqrt{2}x_2 \quad (2.39)$$

$$\phi_4(x) = x_1^2 \quad (2.40)$$

$$\phi_5(x) = x_2^2 \quad (2.41)$$

$$\phi_6(x) = \sqrt{2}x_1x_2 \quad (2.42)$$

Bu durumda karar hiper düzlemi (2.43) nolu ifadeye dönüşürken, fonksiyon (2.44) nolu bağıntı ile ifade edilir. Böylece ikinci dereceden bir hiper düzlemle veriler ayrılabilir.

$$d(z) = w^T z + b \quad (2.43)$$

$$f(x) = [w_1 \quad w_2 \quad w_3 \quad w_4 \quad w_5 \quad w_6] \begin{bmatrix} 1 \\ \sqrt{2}x_1 \\ \sqrt{2}x_2 \\ x_1^2 \\ x_2^2 \\ \sqrt{2}x_1x_2 \end{bmatrix} + b \quad (2.44)$$

En çok kullanılan çekirdek fonksiyonlar, doğrusal, polinom ve radyal tabanlı fonksiyonlardır [154]. Bu tez çalışmasında (2.45) ve (2.46) denkleminde verilen sırasıyla radyal tabanlı ve doğrusal çekirdek fonksiyonları kullanılmaktadır.

$$K(x, y) = \exp^{-\|x-y\|^2 / 2\sigma^2} \quad (2.45)$$


$$K(x, y) = x^T y \quad (2.46)$$

C ceza parametresi ve σ parametresi çapraz doğrulama yöntemiyle belirlenmektedir.

DVM ikili sınıflandırıcıdır. Çok sınıflı verileri ayırmak için birçok yöntem geliştirilmiştir [155,156]. Bunlardan en çok kullanılanı bire karşı bir (one versus one) veya bire karşı diğerleri (one versus another) yöntemleridir [157,158].

2.5.4. k En Yakın Komşuluk Algoritması

En Yakın k komşuluğu algoritması, basit kullanımıyla örüntü tanıma algoritmalarında sıklıkla tercih edilen yöntemlerden biridir. Geniş uygulama alanı bulan en yakın k-komşu algoritması, sınıfları belli olan bir örnek kümesindeki gözlem değerlerinden yararlanarak, örneğe katılacak yeni bir gözlemin hangi sınıfa ait olduğunu belirlemek amacıyla kullanılır [123].



Şekil 2.17. k-EYK sınıf ayrımı gösterimi [109].

Mesela Şekil 2.17’de x_a verisinin $k=5$ komşusuna bakarak sınıfı belirlenecek olursa, şekilden görüldüğü gibi 3 komşusu w_3 sınıfına aitken, 1 komşusu w_1 ve w_2 sınıfına aittir. Bu yöntemle bilinmeyen verinin, en çok komşuluğu bulunduğu sınıfa dahil olduğu kabul edilir. Böylece bilinmeyen x_a verisinin w_3 sınıfına ait olduğu belirlenir. Bu yöntemin adımları aşağıdaki gibi özetlenebilir:

1.adım: k parametresi belirlenir. Bu parametre verilen bir noktaya en yakın komşuların sayısıdır. Bu tez çalışmasında k parametresi çapraz doğrulama yöntemiyle seçilmektedir.

2. adım: Sınıflandırılması istenen nokta ile diğer tüm noktalar arasında uzaklık belirlenir.

3. adım: Hesaplanan uzaklıklardan en küçük k adet uzaklık belirlenir.

4. adım: En yakın k adet komşu saptandıktan sonra bunların sınıflarına bakılır. En çok hangi sınıf tekrarlanmışsa o sınıfa ait olduğu kabul edilir.

İki veri arasındaki uzaklık hesaplanırken birden çok kullanılan uzaklık formülü vardır. Bunlardan en çok kullanılan uzaklık bağıntısı (2.47) ile ifade edilen Öklid uzaklığıdır ve bu çalışmada bu bağıntı tercih edilmektedir.

$$d(i, j) = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (2.47)$$

Burada i ile j noktaları arasındaki uzaklık hesaplanmaktadır. p ise öznitelik sayısını vermektedir. Bir x_i verisinin p kadar özelliği varsa diğer x_j verisinin p kadar özelliği ile

karşılaştırılırken d uzaklığına bakılmaktadır. Öklid uzaklığından başka Manhattan uzaklığı (2.48) bağıntısı da kullanılan bağıntılar arasındadır.

$$d(i, j) = \sum_{k=1}^p |x_{ik} - x_{jk}| \quad (2.48)$$

Bir diğer uzaklık bağıntısına örnek olarak Minkowski uzaklığı (2.49) verilebilir.

$$d(i, j) = \left[\sum_{k=1}^p \left(|x_{ik} - x_{jk}|^m \right) \right]^{1/m} \quad (2.49)$$

Dikkat edilirse (2.49) bağıntısında $m=2$ alınırsa, Öklid uzaklık bağıntısı elde edilir. Çalışmada bu yöntem farklı veri tabanları için çıkartılan özniteliklerin sınıflandırıcı başarısına etkisini incelemekte kullanılırken, önerilen yöntemde ise ikili karar ağacı yapısında kullanılan sınıflandırıcılar arasında yer almaktadır. k-EYK yönteminin uygulanabilirliği, anlaşılabilirliği ve tahminlerinin açıklanabilirliği önemli avantajları arasında yer alırken, yeni bir verinin sınıflandırılmasının uzun zaman alması ve tüm örneklerin saklanması için bellek gereksinimi dezavantajları arasındadır [145].

2.5.6. Önerilen Sınıflandırma Yaklaşımı

Çalışmada öznitelik çıkarma işlemi tamamlanan sensör işaretlerini sınıflandırmak için hibrit bir yöntem önerilmektedir. Bu yöntem, ikili karar ağacı yapısına dayalı diğer sınıflandırıcıların birleşiminden oluşmaktadır. Sınıflandırma ve öznitelik seçme aşamalarını birleştiren bu yöntemin en önemli özelliği ve avantajı ikili karar ağacının dallarında en iyi sınıflandırmayı sağlayacak öznitelik alt kümesini ve sınıflandırıcıyı seçme olanağı sunmasıdır. Böylece her dalda sınıflandırılacak veri için en iyi öznitelikler ve sınıflandırma algoritması bulunarak, kullanılan veri tabanı için en uygun model seçilmiş olur.

Çok sınıflı veri tabanları için çalışmada oluşturulan ikili karar ağacı yapılarının dallanması, her veri tabanındaki ayırt edilecek sınıflardaki sürekli durum verilerinin genlikleri dikkate alınarak yapılandırılmıştır. Gerektiğinde birbirine yakın genlik

değerlerine sahip veriler aynı sınıfta değerlendirilmektedir. Bu yapılandırma tüm sınıflandırma ihtimalleri denenerek de yapılabilirken, bu fazla sınıflı algoritmalarda fazla hesaplama yükü getireceğinden çok sınıflı veri tabanlarında tercih edilmedi. Sınıf sayısı küçük olan veri tabanlarında ise eğitim verisi sınıflandırıldığında en başarılı sonucu verecek dallanma yine çapraz doğrulama yöntemi kullanılarak belirlenmektedir. Böylece ikili karar ağacı yapısının şekli farklı veri tabanları için farklı yapıda oluşturulmuştur.


n-butanol gazının farklı konsantrasyon değerlerinden oluşan VERİ1'in sınıflandırılmasında oluşturulan ikili karar ağacı yapısı Şekil 2.18'de gösterilmektedir. İkili karar ağacında, her düğümdeki sınıflandırıcı kendine gelen veriyi 1 ve 0 olmak üzere ikiye ayırmaktadır. Şekil 2.18'deki ikili karar ağacının ilk karar düğümü ilk 10 sınıfı son 10 sınıftan ayırmaktadır. Bilinmeyen veri uygulandığında eğer veri ilk 10 sınıfa aitse sınıflandırıcı çıkışı 1, eğer veri son 10 sınıfa aitse sınıflandırıcı çıkışı 0 üretir. Her düğümde kullanılan sınıflandırma algoritması ve öznitelikler çapraz doğrulama sonucunda en başarılı sınıflandırma sonucunu veren algoritma ve özniteliklerden belirlenmektedir. Bu da, düğüme gelen veriyi en iyi ayıracak sınıflandırma algoritmasının ve öznitelikliğin verinin yapısına göre seçilme olanağı sunmaktadır. Böylece sınıflandırıcı başarısı artmaktadır. VERİ1 grubundaki sınıflar Tablo 2.13'de verilmektedir.

İkili karar ağacı tabanlı önerilen algoritmanın verinin sınıfına karar vermesinde ikili düzen kullanılmaktadır. Örnek verilecek olursa bilinmeyen verinin 5 ppm olması için karar ağacı yapısındaki sınıflandırıcı sonuçlarının '11111' olması gerekmektedir. VERİ1 için sınıflara karşılık gelen karar ağacı sonuçları Tablo 2.13'de verilmektedir. Ayrıca bilinmeyen verinin bir sınıfa atanabilmesi için geçmesi gereken düğümlerde aynı tablonun son sütununda gösterilmektedir.

Bu veri tabanı 20 sınıftan oluştuğu için sınıflar 5 bitle ifade edilmektedir. Bazı sınıfların ikili düzendeki karşılığında 'x' biti gözükmemektedir. Bu bitin anlamı 'don't care' anlamına gelen o bite karşılık gelen değer 1 veya 0 olmasının durumu değiştirmemesidir. Bu önerilen yapıda kullanılan sınıflandırıcı sayısı, veri tabanındaki sınıf sayısı n olmak üzere $(n-1)$ 'dir.

Tablo 2.13. VERİ1 için sınıf ve ikili karar ağacı bilgileri

Sınıf No.	Konsantrasyon Değeri (ppm)	Sınıfın ikilik düzen karşılığı	Test verisinin geçmesi gereken düğümler
1	5	11111	1, 2, 4, 8, 16
2	10	11110	1, 2, 4, 8, 16
3	25	1110x	1, 2, 4, 8
4	50	1101x	1, 2, 4, 9
5	100	1100x	1, 2, 4, 9
6	120	10111	1, 2, 5, 10, 17
7	240	10110	1, 2, 5, 10, 17
8	250	1010x	1, 2, 5, 10
9	480	1001x	1, 2, 5, 11
10	500	1000x	1, 2, 5, 11
11	960	01111	1, 3, 6, 12, 18
12	1000	01110	1, 3, 6, 12, 18
13	1940	0110x	1, 3, 6, 12
14	2500	0101x	1, 3, 6, 13
15	3880	0100x	1, 3, 6, 13
16	5000	00111	1, 3, 7, 14, 19
17	7750	00110	1, 3, 7, 14, 19
18	10000	0010x	1, 3, 7, 14
19	15550	0001x	1, 3, 7, 15
20	20000	0000x	1, 3, 7, 15



Şekil 2.18. VERİ1 için önerilen yöntemde ikili karar ağacının yapısı

Çok fazla sınıfa sahip veri tabanlarında önerilen algoritmanın eğitim ve test adımları aşağıdaki gibidir.

1. adım: Sınıflandırma modeli kurulurken çoklu sınıflandırmada ilk olarak kendisine gelen eğitim verisinden birbirine yakın genliklere sahip eğitim verileri ikiye ayrılır.

2. adım: Bu eğitim verilerinin sayısı az ise birini dışarıda bırakan çapraz doğrulama ile her seferinde 1 veriyi test için dışarıda bırakarak, kalanlarla model eğitilir. Dışarıda kalan veriyle de test edilir. Tüm eğitim verisi için bu tekrarlanır.

3. adım: 2. adım'daki eğitim aşamasında AIS öznitelik seçme algoritması uygulanarak uygulanan sınıflandırma algoritması için en uygun öznitelikler seçilir. Öznitelikler, öznitelik çıkarma aşamasında en başarılı sonucu veren alt örnekleme yöntemiyle elde edilen özniteliklerden seçilir. Daha sonra da sınıflandırma performansı 2. adımdaki çapraz doğrulama ile belirlenir.

4. adım: 2. adım ve 3. adım farklı sınıflandırma yöntemleri için tekrarlanır. Bu çalışmada DVM, Bayes sınıflandırma, DAA ve k-EYK algoritmaları kullanılmaktadır. İçlerinden en iyi sonucu veren sınıflandırma algoritması ve ona ait öznitelikler ilk düğüm için belirlenir. Eğer aynı sonucu veren sınıflandırma algoritmaları varsa içlerinden en az özniteliği kullanan algoritma seçilir. Bu durumda da bir eşitlik söz konusuysa, algoritmaların hız performansına bakılır ve en hızlı sınıflandırmayı gerçekleştiren seçilir.


5. adım: Tüm sınıflandırıcı düğümler için 1, 2, 3, ve 4. adımlar tekrarlanır. Düğümün tüm dalları yaprakla sonuçlanıyor ise işlem sonlandırılır.

6. adım: Modeli kurulan ikili karar ağacı yapısına bilinmeyen bir veri uygulandığında, bu veri düğümde elde edilen sonuca göre bir yaprağa ulaşana kadar bir sonraki düğüme geçer. Ulaştığı yapraktaki sonuç bilinmeyen verinin sınıfı olarak atanır.

Önerilen yöntemde modelin oluşturulma aşamasının uzun zaman gerektirdiği gözlenirse de, tüm düğümlere tüm eğitim verilerinin değil, sadece sınıflandıracağı veri grubunun uygulandığı göz önünde bulundurulmalıdır. Bir kez model kurulduktan sonra, test aşamasının hız performansı bulgular ve irdeleme kısmında değerlendirilmektedir ve hız performansı açısından çok belirgin farklar olmadığı ortaya konmaktadır.

Farklı kokulardan oluşan VERİ2'de verileri ayırmak için oluşturulan karar ağacı yapısı Şekil 2.19'da gösterilmektedir. Bu ikili karar ağacı yapısındaki sınıf numaraları, bunlara ait olan sınıflar, sınıfların ikilik düzende karşılığı ve test verisinin o sınıfta olabilmesi için geçmesi gereken düğümler Tablo 2.14'de gösterilmektedir.

VERİ2’de de sınıf sayısı fazla olduğundan yukarıda önerilen ikili karar ağacı tabanlı sınıflandırma modelinin adımları aynen bu veri tabanına da uygulanmaktadır. Yani birbirine yakın genliklere sahip veriler belirlenerek verinin ikiye ayrılması gerektiği durumlarda aynı sınıfa ait değerlendirilir. Bu veri tabanı için oluşturulan karar ağacı incelendiğinde ilk 3 sınıfın birbirine daha yakın genlik değerleri ürettiği, son 8 sınıfın da kendi içinde birbirine daha yakın genlik değerleri ürettiği bulgular ve irdelemeler kısmında gözlenmektedir. Yine bilinmeyen bir test verisinin uygulanması durumunda hangi düğümleri geçtiğinde hangi sınıfa atanacağı Tablo 2.14’de verilmektedir. Mesela bilinmeyen bir veri 1, 3, 6 ve 9. düğümlerden geçerek, ‘0011’ sonucunu üretiyorsa bu modelde yumurta kokusu sınıfına atanır.




Şekil 2.19. VERİ2 için önerilen yöntemle oluşturulan ikili karar ağacının yapısı

Balık tazeliğinin tespiti için oluşturulan VERİ3 verilerini ayırmak için elde edilen karar ağacı yapısı Şekil 2.20’de gösterilmektedir.

Tablo 2.14. VERİ2 için sınıf ve ikili karar ağacı bilgileri

Sınıf No	Sınıf	Sınıfın İkilik Düzen Karşılığı	Test Verisinin Geçmesi Gereken Dğümler
1	Limon	111x	1,2,4
2	Aseton	110x	1,2,4
3	Oje	10xx	1,2
4	Naftalin	0111	1,3,5,7
5	Gülsuyu	0110	1,3,5,7
6	Melekotu	0101	1,3,5,8
7	Nane	0100	1,3,5,8
8	Yumurta	0011	1,3,6,9
9	Çürük Yumurta	0010	1,3,6,9
10	Sarımsak	0001	1,3,6,10
11	Çimen	0000	1,3,6,10



Şekil 2.20. VERİ3 için önerilen yöntemle oluşturulan ikili karar ağacının yapısı

Bu sınıflandırıcı balıkların kaç günlük olduğunun tespitinde kullanılmaktadır. 11 ve 13 günlük balıkların kokuları artık çürüme seviyesinde olduğu için diğer günlerden rahatlıkla ayırt edilebilmektedirler. Bu veri tabanında sınıflandırmanın zor olduğu kısım ise balıqçı ortamında saklanmış 3, 5, 7 günlük balığı birbirinden ayırt etmektir. Bu hibrit modelin avantajı iç içe girmiş verileri ayırt etmek için sadece o kısma odaklanılmasını sağlar ve sadece o bölgedeki veriyi başarıyla ayırt edecek en iyi yöntem ve özneliliklerin bulunmasını sağlar. Kısaca problemi parçalara ayırarak çözülmesine olanak sağlamaktadır.

VERİ3 için oluşturulan ikili karar ağacı yapısındaki sınıf numaraları, bunlara ait olan sınıflar, sınıfların ikilik düzende karşılığı ve test verisinin o sınıfta olabilmesi için geçmesi gereken düğümler Tablo 2.15’de gösterilmektedir.


VERİ3 için ikili karar ağacı modeli oluşturulurken yine yukarıda bahsedilen önerilen metodun adımları izlenmektedir. Bu önerilen ikili karar ağacının sınıflandırma performansını ne kadar arttırdığı ve diğer yöntemlerle karşılaştırılması bulgular ve irdemeler kısmında verilmektedir. Şekil 2.20’deki 6 sınıflandırıcıda kullanılacak sınıflandırma yöntemi k-EYK, DVM, DAA ve Bayes sınıflandırma algoritmalarından seçilmektedir. Mesela 1. sınıflandırıcı verileri 9. günden küçük ve eşit ve 9. günden büyük günler olmak üzere iki gruba ayırır. Her sınıflandırıcı kendine gelen veriyi ikiye ayırarak 6 sınıf için sonuç elde edilir.

Tablo 2.15. VERİ3 için sınıf ve ikili karar ağacı bilgileri

Sınıf No.	1	2	3	4	5	6	7
Sınıf (Kaç günlük)	1	3	5	7	9	11	13
Sınıfın ikilik düzen karşılığı	1111	1110	1101	1100	10xx	01xx	00xx
Test verisinin geçmesi gereken düğümler	1,2,4,5	1,2,4,5	1,2,4,6	1,2,4,6	1,2	1,3	1,3

Bu yöntemde literatürdeki benzer yöntemlerden farklı olarak, her düğümdeki sınıflandırıcı da öznitelik alt küme seçimi uygulanmakta ve her sınıflandırıcı veriyi farklı öznitelik ve farklı sayıda öznitelikle sınıflandırmaktadır. Bunun da sınıflandırma performansını arttırdığı bulgular ve irdeme kısmında gözlenmektedir.

Son olarak farklı 3 çeşit balığı ayırt etmek için oluşturulan VERİ4 verilerini ayırmak için oluşturulan karar ağacı yapısı şekil 2.21’de gösterilmektedir. VERİ4 için oluşturulan ikili karar ağacı yapısındaki sınıf numaraları, bunlara ait olan sınıflar, sınıfların ikilik düzende karşılığı ve test verisinin o sınıfta olabilmesi için geçmesi gereken düğümler Tablo 2.16’da verilmektedir.



Şekil 2.21. VERİ4 için önerilen yöntemle oluşturulan ikili karar ağacının yapısı

Tablo 2.16. VERİ4 için sınıf ve ikili karar ağacı bilgileri

Sınıf No.	1	2	3
Sınıf	İstavrit	Hamsi	Mezgit
Sınıfın ikilik düzen karşılığı	11	10	0x
Test verisinin geçmesi gereken düğümler	1,2	1,2	1

Bu veri tabanında veri sayısı az olduğundan dolayı ikili karar ağacı modeli oluşturulurken tüm olasılıklar denenerek en başarılı sonucu Şekil 2.21'deki modelin verdiği tespit edilmektedir.

2.6. Sınıflandırma Performans Ölçütleri

E-burun uygulamaları için ideal örüntü tanıma algoritmasının sahip olması gereken nitelikler aşağıdaki gibi sıralanabilir [158].

- Yüksek doğruluk
- Hız
- Eğitim kolaylığı
- Düşük Bellek gereksinimi

Tüm bu kriterlerin gereksinimlerini aynı anda yerine getiren bir algoritma maalesef mevcut değildir. Hangi kriterin daha önemli olduğu ise uygulama alanına göre değişmektedir. Mesela zehirli gazları algılamada yüksek doğruluk kriteri ön plana çıkmaktadır. Başarının düşük olduğu uygulamalar insan hayatını tehlikeye atacağı için tercih edilmemelidir. Gerçek zamanlı uygulamalarda ise hız kriteri önem kazanmaktadır. Uygulama alanına göre kriterlerin önem sırası değişmektedir.

Çalışmada gerçek zamanlı çalışmalara henüz değinilmediği için ağırlıklı olarak sınıflandırma doğruluğu üzerinde durulmuş ve buna göre performans kriterleri belirlenmiştir. Sınıflandırmada oluşturulan modelin başarısını belirlemek için kullanılan başarı ölçütleri doğruluk oranı, hata oranı, belirlilik (specificity), duyarlılık (sensitivity) gibi değerlerdir [149,159]. Tablo 2.17’de gösterilen karışıklık matrisi (confusion matrix) bu ölçütleri gözlemlemek için oluşturulmuş bir matristir. Tablo 2.17’de belirtilen DP, DN, YN ve YP değerleri sırasıyla doğru pozitif, doğru negatif, yanlış negatif ve yanlış pozitif diye adlandırılmaktadır.

Tablo 2.17. Karışıklık matrisi

DOĞRU SINIF	ÖNGÖRÜLEN SINIF		
		Sınıf 1	Sınıf 2
	Sınıf 1	a (DP)	b (YN)
	Sınıf 2	c (YP)	d (DN)

Bunun anlamı, a değeri birinci sınıfa doğru atananların sayısı, d değeri ise ikinci sınıfa doğru atananlarının sayısını ifade etmektedir. Aynı şekilde b sayısı normalde birinci sınıfa atanması gerekirken ikinci sınıfa atananların sayısını göstermektedir. Benzer şekilde c sayısı da normalde ikinci sınıfa atanması gerekirken birinci sınıfa atananların sayısını göstermektedir. Doğruluk oranı doğru sınıflandırılan verilerin toplam verilere oranı olarak (2.50) bağıntısıyla ifade edilebilir. Hata oranı (2.51) bağıntısıyla verilen hatalı sınıflandırılan verilerin toplam verilere olan oranı ifade etmektedir.

$$\text{Doğruluk oranı} = (\%) \frac{a + d}{a + b + c + d} \times 100 = (\%) \frac{DP + DN}{DP + YP + DN + YN} \times 100 \quad (2.50)$$

$$\text{Hata oranı} = (\%) \frac{b + c}{a + b + c + d} \times 100 = (\%) \frac{YP + YN}{DP + YP + DN + YN} \times 100 \quad (2.51)$$

Duyarlılık doğru sınıflandırılmış pozitif örnek sayısının pozitif sınıflandırılmışların sayısına oranı olarak (2.52) bağıntısıyla elde edilir. Belirlilik değeri ise doğru sınıflandırılmış pozitif örnek sayısının, pozitif atanmışların sayısına oranı olarak (2.53) ifadesiyle elde edilir.

$$\text{Duyarlılık} = (\%) \frac{a}{a+c} \times 100 = (\%) \frac{DP}{DP+YP} \times 100 \quad (2.52)$$

$$\text{Belirlilik} = (\%) \frac{a}{a+b} \times 100 = (\%) \frac{DP}{DP+YN} \times 100 \quad (2.53)$$

Herhangi bir A sınıflandırma modeli herhangi B modelinden daha iyi belirlilik ve duyarlılık değerlerine sahipse A modeli doğruluk açısından daha iyi bir sınıflandırıcıdır denebilir.

3. BULGULAR

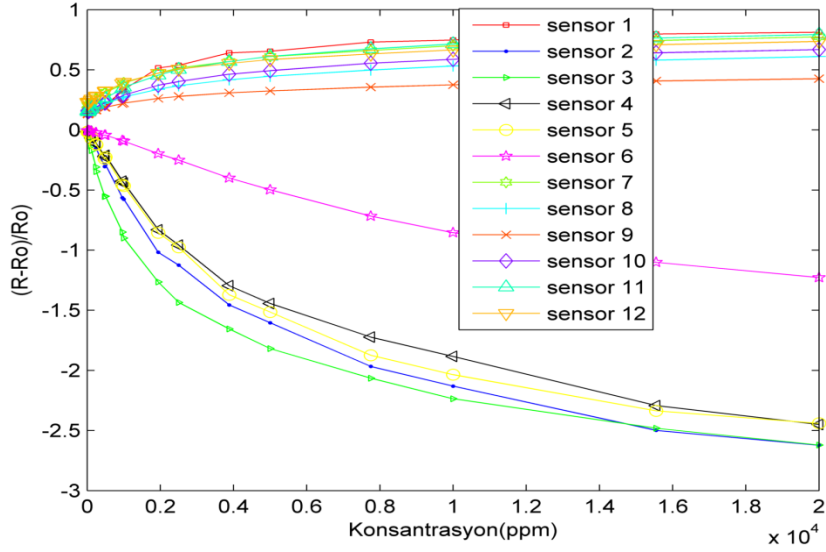
Bu bölümde, tez kapsamında gerçekleştirilen çalışmalara ait bulgular verilmektedir. E-burun genel bilgiler kısmında da belirtildiği gibi koku algılama birimi, işaret ön işleme birimi ve örüntü tanıma birimi olmak üzere 3 ana kısımdan oluşur. Bu bölümde, bu tez çalışmasında kurulan e-burunun her bir birimine ait bulgular kendi içinde ayrı ayrı incelendi. İlk kısımda, sensörlerin farklı veri tabanındaki farklı kokulara verdiği cevap incelenmektedir. Sonraki kısımda, çıkarılan özneliklerin kendi içinde kıyaslamasını yapmak için, farklı özneliklerin oluşturulduğu örüntüler ve bu öznelikler kullanılarak elde edilen sınıflandırma sonuçları incelendi. Son kısımda ise, farklı veri tabanlarına uygulanan sınıflandırma algoritmalarının sonucunda elde edilen bulgular gösterilmektedir.

3.1. Ham Sensör İşaretlerine Ait Deneysel Sonuçlar

Bu çalışmada Bölüm 2’de belirtildiği gibi farklı veri tabanları kullanılmaktadır. Bunlardan VERİ1 hazır veri tabanı olup, diğerleri bu çalışma kapsamında oluşturulan e-burun deney düzeneğinden elde edilen verilerdir. Oluşturulan e-burun deney düzeneğinde sensörlerin etkisini ve sensörlerin farklı kokulara nasıl tepkiler verdiğini anlamak için ilk olarak sensör ham işaretleri incelenmektedir. Literatürde de sıklıkla kullanılan metal oksit sensörlerin, bu çalışmada da farklı veri tabanları için tekrar incelenmesine olanak sağlanmaktadır.

3.1.1. VERİ1’e Ait İşaretler


İlk veri tabanı olan VERİ1 hazır olarak alınan bir veri tabanıdır [135]. Sadece sürekli durum değerinden oluşmaktadır. 12 metal oksit sensörden 20 farklı konsantrasyon değeri için elde edilen ön işleme uygulanan işaretler Şekil 3.1’de gösterilmektedir.




Şekil 3.1. VERİ1'deki farklı konsantrasyon değerleri için 12 sensör değerinin değişimi

Şekil 3.1'den, konsantrasyon değerleri arttıkça sensör direnç oranının bazı sensörler için arttığı bazı sensörler içinse azaldığı gözlemlenmektedir. Bu kullanılan metal oksit sensörün yüzeyinde kullanılan malzeme ile alakalıdır. Sensör 1, 7, 8, 9, 10, 11 ve 12'nin n-butanol gazı ile temaslarında sensör dirençleri artarken, sensör 2, 3, 4, 5 ve 6'nın n-butanol gazı ile temasları sonucunda sensör dirençlerinin azaldığı gözlenmektedir. Sensör değerlerinin konsantrasyon değerlerine göre değişimini daha iyi gözlemlemek için pozitif yönde değişenler ile negatif yönde değişen sensörler ayrı grafikte incelenmiştir. Şekil 3.2'de sensör direnç oranı pozitif yönde artış gösteren sensörlerin direnç oranının konsantrasyonla değişim grafiği gösterilirken, Şekil 3.3'de negatif yönde artış gösteren sensörlerdeki değişim gösterilmektedir.

Şekil 3.2 ve Şekil 3.3 incelendiğinde konsantrasyon değerleri arttıkça n-butanol gazının konsantrasyonunu ayırt etmenin kolaylaştığı, konsantrasyon değerleri azaldıkça ise düşük konsantrasyon değerlerini ayırt etmenin zorlaştığı gözlenmektedir. Önerilen yöntem bu zorluğun üstesinden gelmektedir. Bu yöntemin en önemli özelliklerinden biri de sorunlu bölgeye odaklanarak tek başına ele alınmasına olanak sağlamaktadır. Böylece önerilen yöntem sınıflandırmayı daha başarılı şekilde sonuçlandırmaktadır.



Şekil 3.2. Pozitif yönde artış gösteren sensörlere ait sensör direnç oranı ile konsantrasyonun değişim grafiği




Şekil 3.3. Negatif yönde artış gösteren sensörlere ait sensör direnç oranı ile konsantrasyonun değişim grafiği


3.1.2. VERİ2'ye Ait İşaretler

VERİ2 tez çalışması kapsamında kurulan e-burun deney düzeneğinden elde edilmektedir. Kurulan deney düzeneğine ilk olarak, koku duyusu olarak birbirinden oldukça uzakta olan kokular uygulandığında 8 sensörden elde edilen ham işaretler bu kısımda gösterilecektir.


Bu veri setinde; limon, aseton, naftalin, gül suyu, oje, melekotu kökü, nane, sarımsak, çimen, çürük ve çürük olmayan yumurta kokuları örnek olarak kullanılmıştır. Her sınıfa ait birer koku örnekleri sırasıyla Şekil 3.4 - 3.14 arasında gösterilmektedir.




Şekil 3.4. Limon kokusu için 8 sensörden elde edilen ham işaretler




Şekil 3.5. Aseton kokusu için 8 sensörden elde edilen ham işaretler




Şekil 3.6. Naftalin kokusu için 8 sensörden elde edilen ham işaretler




Şekil 3.7. Gül suyu kokusu için 8 sensörden elde edilen ham işaretler



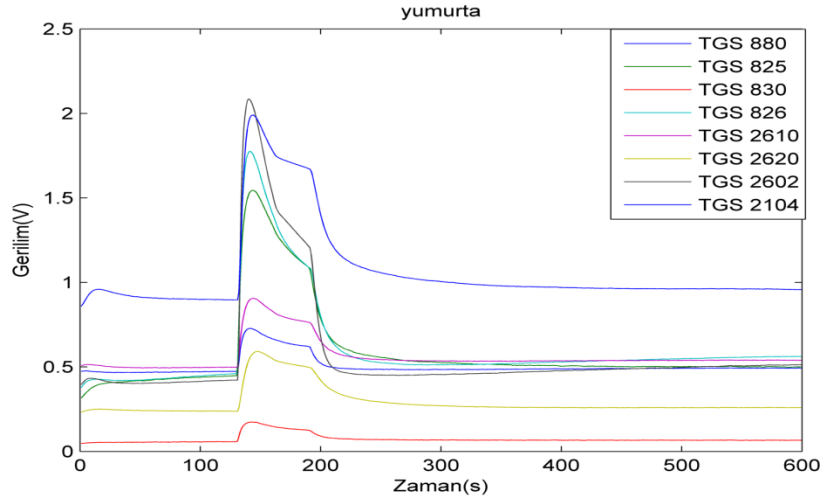
Şekil 3.8. Oje kokusu için 8 sensörden elde edilen ham işaretler




Şekil 3.9. Melekotu kökü kokusu için 8 sensörden elde edilen ham işaretler




Şekil 3.10. Nane kokusu için 8 sensörden elde edilen ham işaretler




Şekil 3.11. Yumurta kokusu için 8 sensörden elde edilen ham işaretler



Şekil 3.12. Çürük yumurta kokusu için 8 sensörden elde edilen ham işaretler



Şekil 3.13. Sarımsak kokusu için 8 sensörden elde edilen ham işaretler




Şekil 3.14. Çimen kokusu için 8 sensörden elde edilen ham işaretler


Her şekilde, örnek koku uygulandığında 8 sensörün verdiği cevap gözükmemektedir. Şekil 3.4 – 3.14 incelendiğinde; her bir sensörün aynı kokuya verdiği cevap farklı olduğu gibi, aynı sensörün farklı kokulara verdiği cevap da farklıdır. Bu çalışmada bu farklılıklardan yararlanarak sınıflandırma yapılmaktadır.

3.1.3. VERİ'e Ait İşaretler


VERİ3 farklı günlerde ölçüm yapılan Karadeniz istavrit balığının kokularından oluşmaktadır. Bu veri tabanında 8 sensörden elde edilen ham işaretler Şekil 3.15-3.21'de verilmektedir. Bu şekiller incelendiğinde, her geçen gün sensörlerin üzerine düşen gerilimin arttığı gözlenmektedir. Bu veri tabanının kullanılmasındaki amaç, birbirine yakın kokular uygulandığında e-burun deney düzeneğinin ve önerilen yöntemin başarısını gözlemlemektir. Aynı zamanda tez çalışmasında kurulan e-burun ile, gıda sektöründe kullanılabilecek bir uygulama gerçekleştirilmektedir.




Şekil 3.15. 1 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler




Şekil 3.16. 3 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler




Şekil 3.17. 5 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler




Şekil 3.18. 7 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler



Şekil 3.19. 9 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler



Şekil 3.20. 11 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler




Şekil 3.21. 13 günlük istavrit kokusu için sensörlerden elde edilen ham işaretler


Bu veri tabanında sınıflandırılacak kokuların birbirine yakın olması sınıflandırma görevini zorlaştırmaktadır. Özellikle birbirine yakın günlere ait istavrit balığının kokusunu ayırt etmenin zorluğu Şekil 3.15-3.21'den anlaşılmaktadır. Literatürde balık tazeliğinin tespiti konusunda yapılan çalışmalarda görülmektedir ki, bu zorluktan dolayı sınıf sayısını azaltma yoluna gidilmektedir [126,139,160,161]. Buna örnek olarak, balık tazeliğini derecelendirerek sınıflandırılma yapılması verilebilir. Çok taze, taze, bayat gibi 3 sınıfa ayırarak sınıflandırma işlemi kolaylaştırılmaktadır. Ama gıda sektöründe; balığın kaç günlük olduğuna göre, farklı işlemlere maruz kalmasından dolayı günlük sınıflandırma yapmak önem kazanmaktadır. Bu yüzden bu veri tabanı için yapılan çalışmayla sınıf sayısı artırılarak gerçek uygulamalarda kullanılabilirliği ölçülmektedir.

3.1.4. VERİ4'e Ait İşaretler


VERİ4 farklı balıklara ait kokulardan oluşmaktadır. Bu veri tabanı için 8 sensörden elde edilen ham sensör işaretleri Şekil 3.22 - 3.24'de verilmektedir. Şekillerde 3 günlük istavrit, hamsi ve mezgıt balık türlerine ait 8 sensörden elde edilen ham işaretler görülmektedir.



Şekil 3.22. İstavrit kokusu için sensörlerden elde edilen ham işaretler



Şekil 3.23. Hamsi kokusu için sensörlerden elde edilen ham işaretler



Şekil 3.24. Mezgit kokusu için sensörlerden elde edilen ham işaretler

Bu veri tabanının sensör işaretleri incelendiğinde benzer kokulardan oluştuğu için sınıflandırma görevinin VERİ2'ye göre zor, 3 sınıf olduğu içinse VERİ3'e göre nispeten daha kolay olduğu gözlenmektedir.


3.2. İşaret Ön İşleme İşlemine Tabi Olan Sensör İşaretlerine Ait Deneysel Bulgular

İşaretleri eşit koşullarda değerlendirmek, koku gürültüsü ve sensör kayma etkilerini en aza indirmek için ham sensör işaretleri ön işlemeye tabi tutulur. Bu çalışmada kullanılan VERİ1, işaret ön işleme uygulanmış, öznelikleri çıkarılmış sensör cevaplarından oluşmaktadır. Bu yüzden VERİ1 için ön işleme ve öznelik çıkarma bulguları elde edilemediğinden irdelenmedi.


3.2.1. VERİ2 İçin Ön İşleme İşlemi ve Deneysel Bulguları

VERİ2'de bulunan 11 farklı kokudan elde edilen işaretlere sırasıyla; Bölüm 2'de kısmında detaylı anlatılan gerilim değerinden iletkenliğe çevirme, ortam kokusunun çıkarılması ve referans düzeltme işlemleri uygulanmaktadır. Bazı kokular için işaret ön işleme aşamaları Şekil 3.25 - 3.33'de gösterilmektedir.


İşaret ön işleme uygulandıktan sonra elde edilen işaretler Şekil 3.25-3.33'de incelendiğinde, sensörlerin temel seviyesinin referans gaza göre eşitlendiği ve sensör kaymalarının etkisinin azaldığı gözlenmektedir.




Şekil 3.25. Naftalin kokusu için 8 sensörün iletkenlik değişimi




Şekil 3.26. Naftalin kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.27. Naftalin kokusu için referans düzeltme uygulanan sensör işaretleri




Şekil 3.28. Çürük yumurta kokusu için 8 sensörün iletkenlik değişimi




Şekil 3.29. Çürük yumurta kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.30. Çürük yumurta kokusu için referans düzeltme uygulanan sensör işaretleri



Şekil 3.31. Çimen kokusu için 8 sensörün iletkenlik değişimi





Şekil 3.32. Çimen kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.33. Çimen kokusu için referans düzeltme uygulanan sensör işaretleri


Sensörlerin hangisinin hangi kokuya hassasiyetinin fazla ya da az olduğunu anlamak ve farklı kokuların kendi aralarında dağılımını görmek için, bir sensörün tüm kokulara verdiği cevapları incelemek gerekir. Bu veri grubunda hepsini tek bir grafikte gözlemlemek mümkün olmadığı için, büyük genlikliler ile küçük genlikli iletkenlik değerlerini veren sensör cevapları birbirinden ayrılmaktadır. Şekil 3.34 – 3.38’de bazı sensörler için aynı grafikte farklı kokulara verdiği cevaplar gözükmemektedir.



Şekil 3.34. TGS 880 sensörünün a) limon, aseton ve oje b) naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta ve sarımsak için işaret ön işleme uygulanan işaretleri





(a)





(b)


Şekil 3.35. a) TGS 826 sensörünün limon, aseton ve oje için b) TGS 826 sensörünün naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta ve sarımsak için işaret ön işleme uygulanan işaretleri




Şekil 3.36. a) TGS 2610 sensörünün limon, aseton ve oje için b) TGS 2610 sensörünün naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta ve sarımsak için işaret ön işleme uygulanan işaretleri



Şekil 3.37. a) TGS 2602 sensörünün limon, aseton ve oje için b) TGS 2602 sensörünün naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta ve sarımsak için işaret ön işleme uygulanan işaretleri



(a)




(b)

Şekil 3.38. a) TGS 2104 sensörünün limon, aseton ve oje için b) TGS 2104 sensörünün naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta, çimen ve sarımsak için işaret ön işleme uygulanan işaretleri


Şekil 3.34-3.38 grafikleri incelendiğinde naftalin, gül suyu, melekotu kökü, nane, yumurta, çürük yumurta, çimen ve sarımsak kokularına en çok iletkenlik değişimini gösteren sensörlerin sırasıyla TGS 2602, TGS 826 ve TGS 2104 sensörleri olduğu tespit edilmektedir. Limon, aseton ve oje kokuları için ise genel olarak tüm sensörlerin yüksek iletkenlik değişimi gösterdiği gözlenmektedir. Bu durumdan dolayı, bu üç kokuyu sınıflandırma işlemi diğer kokularla kıyaslandığında daha kolay gerçekleşmektedir.

3.2.2. VERİ3 İÇİN ÖN İŞLEME İŞLEMİ VE DENEYSEL BULGULARI


VERİ3 13 gün içinde kaydedilen Karadeniz istavrit balığı kokularından oluşmaktadır. Bu veri tabanındaki kokulara ön işleme aşaması olarak, ham koku işaretlerinden ilk olarak ortam havası için elde edilen sensör işaretleri çıkartılmaktadır. Ortam havası çıkartılan sensör işaretleri gerilimden iletkenliğe dönüştürülmektedir. İletkenlik değerleri elde edilen sensör işaretlerine referans düzeltme uygulanarak sensör kaymaları problemi azaltılmaya çalışılmaktadır. Bazı günlere ait balık kokularına uygulanan ön işleme sonucunda elde edilen işaretler Şekil 3.39-3.47’de görülmektedir.




Şekil 3.39. 1 günlük istavrit kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.40. 1 günlük istavrit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri




Şekil 3.41. 1 günlük istavrit kokusu için referans düzeltme uygulanan sensör işaretleri




Şekil 3.42. 7 günlük istavrit kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.43. 7 günlük istavrit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri




Şekil 3.44. 7 günlük istavrit kokusu için referans düzeltme uygulanan sensör işaretleri



Şekil 3.45. 11 günlük istavrit kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.46. 11 günlük istavrit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri




Şekil 3.47. 11 günlük istavrit kokusu için referans düzeltme uygulanan sensör işaretleri


VERİ3 için örnek verilen Şekil 3.15-3.21'de ham sensör işaretlerine ön işaret işleme uygulandığında elde edilen işaretlere bazı günler için örnekler Şekil 3.39- 3.47'de verilmektedir. Ham işarete ön işleme uygulandıktan sonra elde edilen işaretlerdeki düzelme gözükmemektedir. Sensörlerin hassasiyetini gözlemleyebilmek için, farklı günlerdeki istavrit balığı kokuları için bazı sensör cevaplarının ön işlenmiş hali Şekil 3.48 - 3.51'de gözlenmektedir.




Şekil 3.48. TGS 880'nin farklı günler için istavrit kokularına verdiği sensör cevapları



Şekil 3.49. TGS 2610'nun farklı günler için istavrit kokularına verdiği sensör cevapları



Şekil 3.50. TGS 2602'nin farklı günler için istavrit kokularına verdiği sensör cevapları




Şekil 3.51. TGS 2104'ün farklı günler için istavrit kokularına verdiği sensör cevapları


Şekil 3.48-3.51 incelendiğinde 9, 11 13 günlük balık kokularının kolaylıkla ayırt edildiğini ama 1, 3, 5 ve 7 günlük balık kokularına ait işaretlerin birbirine yakın olduğu gözlenmektedir. Yine şekiller incelendiğinde, balık kokusuna en çok tepki veren sensörlerin TGS 2602, TGS 2104, TGS 826 sensörleri olduğu gözlenmektedir.

3.2.3. VERİ4 İçin Ön İşleme İşlemi ve Deneysel Bulguları


3 farklı balık kokusundan oluşan VERİ4 için ham işaretlere uygulanan işaret ön işleme aşamaları Şekil 3.52-3.60'da gösterilmektedir. İlk ön işleme aşaması olarak balık kokuları için elde edilen sensör işaretlerinden, ortam havasından elde edilen sensör işaretleri çıkartılmaktadır. Sonra, bu işaret iletkenliğe dönüştürülerek, referans düzeltme işlemine tabi tutulur.




Şekil 3.52. İstavrit kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.53. İstavrit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri




Şekil 3.54. İstavrit kokusu için referans düzeltme uygulanan sensör işaretleri




Şekil 3.55. Hamsi kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.56. Hamsi kokusu için iletkenliğe dönüştürülmüş sensör işaretleri




Şekil 3.57. Hamsi kokusu için referans düzeltme uygulanan sensör işaretleri



Şekil 3.58. Mezgit kokusu için ortam havası çıkarılan sensör işaretleri




Şekil 3.59. Mezgit kokusu için iletkenliğe dönüştürülmüş sensör işaretleri




Şekil 3.60. Mezgit kokusu için referans düzeltme uygulanan sensör işaretleri


Şekil 3.52-3.60'da VERİ4'deki ön işleme uygulanan işaretlerde sensör kaymalarının düzeldiği gözlenmektedir. Sensör hassasiyetini gözlemlemek için, her bir sensörün farklı balık kokularına verdiği cevaplar Şekil 3.61-3.65 arasında gösterilmektedir. Bu şekiller incelendiğinde, balık kokularına en çok tepkiyi veren sensörler TGS 2602, TGS 2104 ve TGS 826 olarak gözlenmektedir. Ama hangi sensörlerin farklı balık kokularını daha iyi ayırt ettiği incelendiğinde ise, TGS 2620, TGS 826 ve TGS 880 sensörleri öne çıkmaktadır.




Şekil 3.61. TGS 880'in farklı balık kokularına verdiği sensör cevapları




Şekil 3.62. TGS 825'in farklı balık kokularına verdiği sensör cevapları




Şekil 3.63. TGS 826'nın farklı balık kokularına verdiği sensör cevapları



Şekil 3.64. TGS 2620'nin farklı balık kokularına verdiği sensör cevapları



Şekil 3.65. TGS 2602'nin farklı balık kokularına verdiği sensör cevapları



Şekil 3.66. TGS 2104'nin farklı balık kokularına verdiği sensör cevapları

3.3. Öznitelikler ile İlgili Elde Edilen Bulgular


Sensörlerin zaman cevapları üzerinden çıkartılan farklı öznitelikler bu bölümde karşılaştırılmaktadır. Literatürde sıklıkla kullanılan öznitelik değeri olarak, sensör sürekli durum değeri, bu çalışmada sensör cevaplarının geçici durumundan çıkartılan öznitelikler ile karşılaştırılmaktadır. Karşılaştırmak üzere çıkartılan tüm öznitelikleri sınıflandırmak için en yakın komşu algoritması kullanılmaktadır. VERİ1 sadece sürekli durum değerlerinden oluştuğu için, bu veri tabanında farklı öznitelikler için karşılaştırma yapılamadı.

3.3.1. VERİ2'ye Ait Öznitelikler ile İlgili Elde Edilen Bulgular


Bölüm 2.4.3'de detayları anlatılan öznitelik çıkarma yöntemleri sırasıyla farklı 11 kokuyu içeren VERİ2'ye uygulanmaktadır. En iyi öznitelik grubunu belirlemede çıkarılan öznitelik grupları bütünüyle sınıflandırıcıya uygulanarak, öznitelik seçme aşamasına tabi tutulmamaktadır. En iyi öznitelik grubu belirlendikten sonra en başarılı sonucu veren öznitelik grubuna öznitelik seçme işlemi uygulanmaktadır.

Bu tez çalışmasında, literatürde en çok kullanılan öznitelik olan sürekli durum değeri için sensör cevaplarının maksimum değeri alındı. Her sensörden 1 sürekli durum değeri olarak sensör cevabının maksimum değeri alındığında, bir koku örneği için toplam 8 sensörden 8 öznitelik çıkartılmaktadır. Öznitelik olarak maksimum değer alındığında,


birbirine yakın kokulardan olan naftalin, gülsuyu, melekotu ve nane kokularının örüntüsü için elde edilen veriler Şekil 3.67- 3.70'de gözükmektedir. Bu radar çizimlerinde her koku ölçümlerinden elde edilen 8 öznelik radar grafikte bir eksene karşılık gelmektedir. Grafikteki farklı renkler ise aynı koku örneği için 6 farklı ölçümü göstermektedir. Mesela Şekil 3.67'de farklı renklerdeki radar çizimleri naftalin kokusu için yapılan farklı ölçümleri, radardaki 8 eksen ise 8 sensörden çıkartılan 8 özneliği göstermektedir. Böylece bu öznelikler kullanıldığında ortaya çıkan naftalin kokusu örüntüsü elde edilmektedir. Benzer şekilde diğer kokular içinde radar grafikler Şekil 3.68-3.70'da elde edilmektedir.




Şekil 3.67. Naftalin için 8 sensör ile farklı ölçümlerden elde edilen öznelikler



Şekil 3.68. Gülsuyu için 8 sensör ile farklı ölçümlerden elde edilen öznelikler




Şekil 3.69. Melekotu kökü için 8 sensör ile farklı ölçümlerden elde edilen öznelilikler




Şekil 3.70. Nane için 8 sensör ile farklı ölçümlerden elde edilen öznelilikler

Maksimum değerlere ait radar çizimler incelendiğinde, özellikle melekotu ve nane örüntüleriyle, naftalin ve gül suyu örüntülerinin birbirine çok benzediği gözükmektedir. Bu da sınıflandırma başarısını düşürücü bir etkiye neden olur.

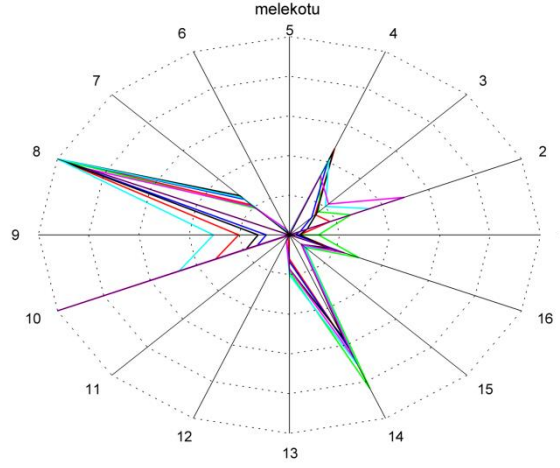
Sensör cevabını yükselen kenar ve düşen kenar olmak üzere ikiye ayırıp, her parçanın integrali alınarak bulunan değerler de öznelilik olarak çıkartılmaktadır. Bir koku örneği bu yöntemle 16 öznelilikle temsil edilmekte ve sınıflandırıcıya uygulanmaktadır. Bu özneliliklerin ayırt ediciliğinin anlaşılması için birbirine benzer kokulardan integral alınarak çıkarılan 16 öznelilikle farklı ölçümler için elde edilen radar çizimleri Şekil 3.71 – 3.74’de gösterilmektedir.




Şekil 3.71. Naftalin için 8 sensör ile farklı ölçümlerden elde edilen öznitelikler



Şekil 3.72. Gülsuyu için 8 sensör ile farklı ölçümlerden elde edilen öznitelikler




Şekil 3.73. Melekotu için 8 sensör ile farklı ölçümlerden elde edilen öznelilikler




Şekil 3.74. Nane için 8 sensör ile farklı ölçümlerden elde edilen öznelilikler

İntegral alınarak çıkarılan özneliliklerin radar çizimleri incelendiğinde nane ile naftalin, oje ile çürük yumurta ve aseton ile melekotu örüntülerinin birbirine yakın olduğu gözlenmektedir. Bu nedenler sınıflandırma başarısını olumsuz etkilemektedir.

Yine sensör cevabını tanımlayıcı parametrelerden ortalama değer, standart sapma, basıklık ve çarpıklık katsayıları öznelilik vektörü olarak alındığında bir sensörden 4 öznelilik, 8 sensörden ise 32 öznelilik elde edilmektedir. Bu özneliliklerle yapılan sınıflandırma sonuçları incelendiğinde çimen, sarımsak ve yumurta kokuları ile nane ve naftalin kokularını ayırtırmakta problemler oluşmaktadır. Bu problem Şekil 3.75 – 3.79'daki öznelilik radar çizimlerinde gözükmemektedir.




(a)




(b)

Şekil 3.75. Yumurta kokusu için a) ilk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öznelitliklerin radar çizimi




(a)




(b)


Şekil 3.76. Sarımsak kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öznelitliklerin radar çizimi



Şekil 3.77. Çimen kokusu için a) ilk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özneliklerin radar çizimi




Şekil 3.78. Naftalin kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özneliklerin radar çizimi




Şekil 3.79. Nane kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özniteliklerin radar çizimi

32 özniteliği tek bir radar çizimde göstermek zor olduğu için, ilk 4 sensör ve son 4 sensörden elde edilen özniteliklerin radar çizimi ayrı gösterilmektedir. Sensör cevaplarının farkını ortaya çıkaran bir diğer yöntem yükselme zamanı, düşme zamanı, maksimuma ulaşma süresi, işaretin yükselen kenarda %60'ına ulaşma süresi, düşen kenarda işaretin % 60'ına ulaşma süresi ve maksimum değer öznitelik vektörü olarak sınıflandırıcıya uygulanmaktadır. Her koku örneği için bir sensörden 6 öznitelik, toplamda 48 öznitelik çıkartılmaktadır. Yine bu yöntemle sınıflandırılma yapıldığında nane, sarımsak, melekotu ve çimen kokularının birbirine yakınlığından dolayı sınıflandırma hataları meydana gelmektedir. 48 özniteliği radar çizimle anlaşılmayacağı düşünüldüğünden, tüm eğitim seti verilerinden elde edilen öznitelikler Box-and-Whisher çizimlerinde gösterilmiştir. Box-and-Whisher çizimlerinde yatay eksende öznitelikler varken, düşey eksende o özniteliklerin dağılımı gözükmemektedir. Birbirine yakın kokulardan olan nane, sarımsak ve çimen kokularına ait elde edilen özniteliklerin Box-and-Whisher çizimleri Şekil 3.80-3.82'de gözükmemektedir. Box-and-Whisher çizimlerinde yatay eksen çıkarılan öznitelikleri düşey eksen de ise özniteliklerin değerleri bulunmaktadır. Grafiğin içindeki kutular ise, özniteliklerin tüm ölçümler için hangi aralıkta değiştiğine, kutuların içindeki çizgi de ortalama değerine karşılık gelmektedir. Böylece tüm ölçümler için elde edilen özniteliklerin dağılımı gözlenebilmektedir.




(a)




(b)

Şekil 3.80. Nane kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özniteliklerin radar çizimi




(a)




(b)

Şekil 3.81. Sarımsak kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özniteliklerin radar çizimi



(a)




(b)


Şekil 3.82. Çimen kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özniteliklerin radar çizimi

Bir diğer öznitelik çıkarma yöntemi, sensör cevabını 6 parçaya ayırarak her parçanın türevinin alınmasıyla bir sensör cevabından 6 öznitelik elde edilmesi şeklindedir. Böylece bir koku örneği için 48 öznitelik çıkartılmaktadır. Şekil 3.83–3.85’den öznitelikler

incelendiğinde, bu özneliklerin yumurta, çürük yumurta ve çimen kokularını ayırt etmekte zorlandığı anlaşılmaktadır.




(a)




(b)

Şekil 3.83. Yumurta kokusu için a) ilk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özneliklerin tüm veriler için dağılımı

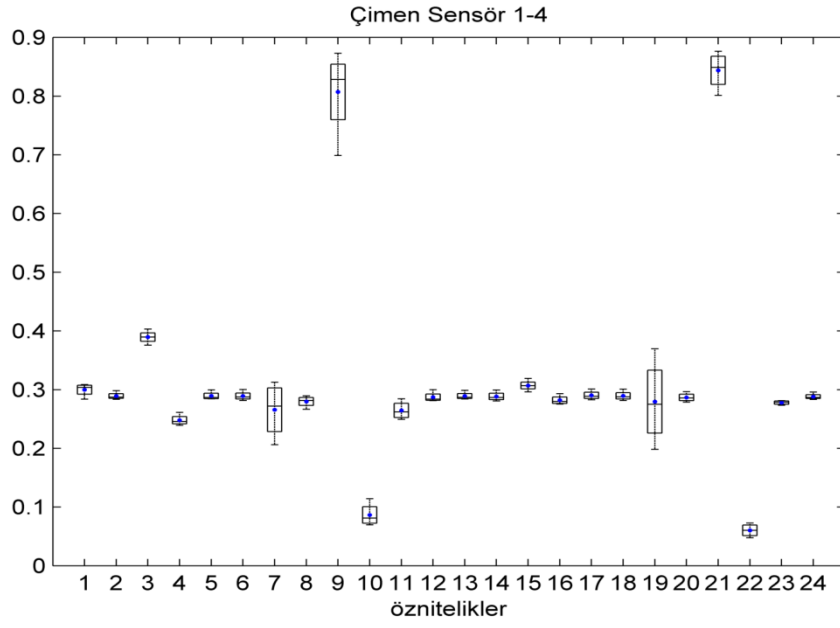


(a)




(b)

Şekil 3.84. Çürük yumurta kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen öz niteliklerin tüm veriler için dağılımı




(a)




(b)

Şekil 3.85. Çimen kokusu için a) İlk 4 sensörden (TGS 880,TGS 825, TGS 830, TGS 826) b) Son 4 sensörden (TGS 2610,TGS 2620, TGS 2602, TGS 2104) elde edilen özniteliklerin tüm veriler için dağılımı

Alt örnekleme yöntemiyle, işaret 60 örnekte bir örneklenmekte ve bir sensörden toplam 10 örnek elde edilmektedir. Öznitelik çıkarılırken karşılaşılan en büyük problemlerden biri işaretle ilgili bilgi kaybının yaşanmasıdır. Sensör cevabı yavaş olduğundan dolayı alt örnekleme yönteminin avantajı işaretin şeklini çok fazla kaybetmeden korunmasını sağlayarak, sensörün bütünüyle ilgili bilgiyi kaybetmeden öznitelik olarak uygulanmasını amaçlamaktadır. Bir sensörden 10 öznitelik çıkarılarak, bir koku örneği için 80 öznitelik elde edilmektedir. Alt örnekleme ile elde edilen öznitelikler kullanıldığında, birbirine en yakın grafiklerin gülsuyu ve melekotu kokuları için kutu grafikleri Şekil 3.86 ve Şekil 3.87’de görülmektedir. Birbirine en yakın olan bu kokular için bile, özniteliklerin ayırt ediciliği şekillerden anlaşılmaktadır.



Şekil 3.86. Gülsuyu kokusu için a) TGS 880 ve TGS 825 b) TGS 830 ve TGS 826 c) TGS 2610 ve TGS 2620 d) TGS 2602 ve TGS 2104 sensörlerinden elde edilen özniteliklerin tüm gülsuyu kokusu verileri için dağılımı



Şekil 3.87. Melekotu kokusu için a) TGS 880 ve TGS 825 b) TGS 830 ve TGS 826 c) TGS 2610 ve TGS 2620 d) TGS 2602 ve TGS 2104 sensörlerinden elde edilen öz niteliklerin tüm veriler için dağılımı

Tüm bu çıkartılan öz nitelikleri kullanarak yapılan sınıflandırma sonuçları Tablo 3.1’ de özetlenmektedir. VERİ2 farklı kokulardan oluştuğu için başarı sonuçları oldukça yüksek çıkmaktadır. Bu başarı sonuçlarından en başarılı olan alt örnekleme yöntemi, öz nitelik seçme ve sınıflandırıcı modelini oluşturmak üzere kullanılmaktadır.


3.3.2. VERİ3’e Ait Öz nitelikler ile İlgili Elde Edilen Bulgular

VERİ3 istavrit balığının farklı günlerde elde edilen kokularından oluşmaktadır. VERİ2’ye uygulanan farklı öz nitelik çıkartma yöntemleri, bu veri tabanına da sırasıyla uygulanarak Şekil 3.88-3.98 elde edildi. Öz nitelik olarak maksimum değer seçildiğinde, birbirine yakın örüntülere sahip olan 5 ve 7 günlük istavrit kokularının örüntüleri Şekil


3.88 ve Şekil 3.89’da verilmektedir. Şekiller incelendiğinde, elde edilen özneliklerin birbirine çok yakın örüntüler oluşturduğu gözlenmektedir. Bu da iki sınıfı birbirinden ayırt etmenin zorluğunu göstermektedir. Öznelik olarak sensör cevaplarının integrali alındığında elde edilen 5 ve 7 günlük istavrit balığı kokularının örüntüleri Şekil 3.90 ve Şekil 3.91’da görülmektedir.

Tablo 3.1. VERİ2 için farklı özneliklerle sınıflandırma sonuçları


Öznelik Yöntemleri	Öznelik Sayısı	k parametresi	Sınıflandırma Başarısı (%)	Standart Sapma
Maksimum Değer	1	7	88.243	±5.43
Türev	6	5	85.805	±4.63
İntegral	2	3	90.688	±6.74
Ortalama, Basıklık, Standart Sapma, Çarpıklık	4	3	83.3669	±4.13
Yükselme Zamanı	6	5	88.243	±7.33
Alt örnekleme yöntemi	10	5	93.122	±4.27




Şekil 3.88. Maksimum değer öznelik olarak alındığında 5 günlük istavrit koku örüntüsü



Şekil 3.89. Maksimum değer öznitelik olarak alındığında 7 günlük istavrit koku örüntüsü




Şekil 3.90. İntegral alma öznitelik olarak seçildiğinde 5 günlük istavrit kokusunun örüntüsü




Şekil 3.91. İntegral alma öznitelik olarak seçildiğinde 7 günlük istavrit kokusunun örüntüsü

Öznitelik olarak ortalama değer, standart sapma, basıklık ve çarpıklık katsayısı alındığında elde edilen 5 ve 7 günlük istavrit balığı görüntüleri Şekil 3.92 ve 3.93'de görülmektedir.




Şekil 3.92. Ortalama değer, standart sapma, basıklık ve çarpıklık katsayısı öznitelik olarak seçildiğinde a) ilk 4 sensör b) son 4 sensör için 5 günlük istavrit kokusunun örüntüsü




Şekil 3.93. Ortalama değer, standart sapma, basıklık ve çarpıklık katsayısı öznitelik olarak seçildiğinde a) ilk 4 sensör b) son 4 sensör için 7 günlük istavrit kokusunun örüntüsü

Şekil 3.92 ve Şekil 3.93 incelendiğinde bu çıkartılan özniteliklerle 5 ve 7 günlük istavrit balığı kokusu örüntülerinin birbirine çok yakın olduğu gözlenmektedir. Diğer bir

öznitelik çıkarma yöntemi olan yükselme zamanı, düşme zamanı, maksimuma ulaşma süresi, yükselen kenarda maksimum değerin % 60'ına ulaşma, düşen kenarda maksimum değerin % 60'ına ulaşma süresi ve maksimum değer alındığında elde edilen 5 ve 7 günlük istavrit balık kokusunun örüntüleri Şekil 3.94 ve 3.95'de gösterilmektedir.




Şekil 3.94. 5 günlük istavrit kokusu için a) TGS 880 ve 825 b) TGS 830 ve 826 c) TGS 2620 ve 2610 d) TGS 2602 ve 2104 sensörlerinden çıkartılan öznitelikler




Şekil 3.95. 7 günlük istavrit kokusu için a) TGS 880 ve 825 b) TGS 830 ve 826 c) TGS 2620 ve 2610 d) TGS 2602 ve 2104 sensörlerinden çıkartılan öznitelikler

Sensör işaretlerinin türevi alınarak elde edilen özniteliklerin 5 ve 7 günlük balık kokusu verilerinin dağılımı Şekil 3.96 ve Şekil 3.97’de gösterilmektedir.




(a)




(b)

Şekil 3.96. 5 günlük istavrit kokusu için elde edilen özniteliklerin dağılımı
a) ilk 4 sensör için b) son 4 sensör için




(a)




(b)

Şekil 3.97. 7 günlük istavrit kokusu için elde edilen öz niteliklerin dağılımı
a) ilk 4 sensör için b) son 4 sensör için

Öz nitelik olarak alt örnekleme alındığında, 5 ve 7 günlük istavrit balığı koku verilerinin dağılımı Şekil 3.98 ve Şekil 3.99 gözükmemektedir.




Şekil 3.98. 5 günlük istavrit için a)TGS 880-825 b) TGS 830-826 c) TGS 2620-2620 d)TGS 2602-2104 sensörleri için alt örnekleme ile elde edilen öznitelikler



Şekil 3.99. 7 günlük istavrit için a)TGS 880-825 b) TGS 830-826 c) TGS 2620-2620 d)TGS 2602-2104 sensörleri için alt örnekleme ile elde edilen öznitelikler

Şekil 3.99'un devamı




Öznitelik çıkarma yöntemlerinin kıyaslaması Tablo 3.2'de yapılmaktadır. Tablo 3.2'de tüm öznitelikler öznitelik seçme kullanılmadan bütün olarak uygulandığında elde edilen sonuçlar kıyaslanmaktadır. Farklı sınıflara ait kokular birbirine yakın kokular olduğu için VERİ2'nin sonuçları ile karşılaştırıldığında sınıflandırıcı başarısının düşmesi beklenen bir sonuçtur. Önerilen sınıflandırma yöntemi ve öznitelik seçme yönteminin önemi bu veri tabanında daha iyi anlaşılmaktadır. Alt örnekleme yöntemi kullanılarak, Tablo 3.2'de belirtildiği gibi diğer yöntemlere oranla daha başarılı sınıflandırma sonucu elde edilmektedir.

Tablo 3.2. VERİ3 için farklı özniteliklerle sınıflandırma sonuçları

Öznitelik Yöntemleri	Öznitelik Sayısı	k parametresi	Sınıflandırma Başarısı (%)	Standart Sapma
Maksimum Değer	1	6	55.557	±8.253
Türev	6	8	52.778	±7.221
İntegral	2	5	50.22	±9.378
Ortalama, Basıklık, Standart Sapma, Çarpıklık	4	3	52.778	±6.342
Yükselme Zamanı	6	3	44.44	±8.743
Alt örnekleme yöntemi	7	8	61.11	±7.332


3.3.3. VERİ4'e Ait Öznitelikler ile İlgili Elde Edilen Bulgular

3 farklı balık cinsine ait kokuları ayırt etmek için diğer veri tabanlarına uygulanan öznitelik çıkarma yöntemleri VERİ4'e de uygulanmaktadır. Öznitelik çıkarma ile ilgili bulgular Şekil 3.100 - 3.113'de verilmektedir. Sırasıyla bu şekiller incelenirse; ilk olarak, öznitelik olarak maksimum değer alındığında 3 farklı balığın 3 günlük kokusu için elde edilen öznitelikler Şekil 3.100'de verilmektedir.




Şekil 3.100. Öznitelik olarak maksimum değerleri alındığında 3 günlük a) istavrit b) hamsi c) mezigit kokusu örüntüleri

Şekil 3.100'de 3 farklı balık için öznitelikler her sensörün maksimum değeri seçildiğinde ortaya çıkan koku örüntüleri incelendiğinde hamsi ve mezigit örüntülerinin birbirine benzerliğinden dolayı tam olarak ayırt edilemeyeceği gözlenmektedir.




Şekil 3.101. Öznitelik olarak integral değerleri alındığında 3 günlük a) istavrit b) hamsi c) mezgıt kokusu örüntüleri


Öznitelik olarak sensör işaretlerinin integrali alındığında ise elde edilen özniteliklerin radar çizimi şekil 3.101’de görülmektedir. Şekil 3.101 incelendiğinde çıkarılan özniteliklerde mezgıt ile hamsinin kokularının birbirine yakın olduğu gözlenmektedir. Öznitelikler olarak sensör işaretlerinin ortalama değeri, standart sapma, basıklık katsayısı ve çarpıklık katsayısı alındığında elde edilen özniteliklerin radar çizimi şekil 3.102-3.104’te görülmektedir.



Şekil 3.102. Öznitelik olarak ortalama değeri, standart sapma, basıklık katsayısı ve çarpıklık katsayısı değerleri alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük istavrit kokusu örüntüsü




Şekil 3.103. Öznitelik olarak ortalama değeri, standart sapma, basıklık katsayısı ve çarpıklık katsayısı değerleri alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük hamsi kokusu örüntüsü




Şekil 3.104. Öznitelik olarak ortalama değeri, standart sapma, basıklık katsayısı ve çarpıklık katsayısı değerleri alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük mezgit kokusu örüntüsü


Şekil 3.102-3.104 incelendiğinde istavrit ve hamsi öznitelikleri örüntülerinin birbirine benzediği gözükmemektedir. Bunun da sınıflandırma performansını olumsuz etkileyeceği anlaşılmaktadır. Öznitelikler olarak sensör işaretlerinin yükselme zamanı, düşme zamanı, maksimuma ulaşma süresi, yükselen kenarda maksimum değerinin % 60'ına ulaşma süresi, düşen kenarda maksimum değerinin % 60'ına ulaşma süresi ve maksimum değer alındığında elde edilen özniteliklerin radar çizimi Şekil 3.105-3.107'de gözükmemektedir.



Şekil 3.105. Öznitelik olarak zaman parametreleri(yükselme zamanı, vb.) alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük istavrit kokusu örüntüsü




Şekil 3.106. Öznitelik olarak zaman parametreleri(yükselme zamanı, vb.) alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük hamsi kokusu örüntüsü




Şekil 3.107. Öznitelik olarak zaman parametreleri(yükselme zamanı, vb.) alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük mezzit kokusu örüntüsü


Şekil 3.105-3.107 incelendiğinde, hamsi ve mezzit koku örüntülerinin birbirine yakın olduğu gözlenmektedir. Öznitelikler olarak sensör işaretlerini 6 parçaya ayırıp her parçanın türevi alındığında elde edilen özniteliklerin radar çizimi Şekil 3.108-3.110'da görülmektedir.



Şekil 3.108. Öznitelik olarak, 6 parçaya ayrılmış sensör cevaplarının türevi alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük istavrit kokusu örüntüsü




Şekil 3.109. Öznitelik olarak, 6 parçaya ayrılmış sensör cevaplarının türevi alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük hamsi kokusu örüntüsü




Şekil 3.110. Öznitelik olarak, 6 parçaya ayrılmış sensör cevaplarının türevi alındığında a) ilk 4 sensör b) son 4 sensör için 3 günlük mezgit kokusu örüntüsü

Şekil 3.108-3.110 incelendiklerinde istavrit ve hamsi koku örüntülerinin yakınlığı gözükmetedir. Ön işleme tabi tutulan sensör işaretlerinden alt örnekleme uygulandığında elde edilen özniteliklerin radar çizimleri Şekil 3.111- 3.113'de gözükmetedir.




Şekil 3.111. Öznitelik olarak alt örnekleme uygulandığında a) TGS 880-825 b) TGS 830-826 c) TGS 2610-2620 d) TGS 2602-2104 sensörleri için 3 günlük istavrit kokusu örüntüsü

Şekil 3.111'in devamı



Şekil 3.112. Öznitelik olarak alt örnekleme uygulandığında a) TGS 880-825 b) TGS 830-826 c) TGS 2610-2620 d) TGS 2602-2104 sensörleri için 3 günlük hamsi kokusu örüntüsü

Şekil 3.112'nin devamı



Şekil 3.113. Öznitelik olarak alt örnekleme uygulandığında a) TGS 880-825 b) TGS 830-826 c) TGS 2610-2620 d) TGS 2602-2104 sensörleri için 3 günlük mezigit kokusu örüntüsü

Şekil 3.111-3.113 incelendiğinde alt örnekleme özniteliklerini kullanıldığında oluşan mezzit koku örüntüsünün farklı olduğu gözlenmektedir. Diğer veri tabanlarında olduğu gibi, burada da amaç en başarılı sınıflandırma doğruluğunu veren yöntemin ve özniteliklerin belirlenip uygulanmasını sağlamaktır. Bu amaçla uygulanan yöntemlerin başarısı Tablo 3.3'de verilmektedir. Yöntemlerin başarısı incelendiğinde alt örnekleme yönteminin % 74 sınıflandırma başarısı ile en yüksek doğruluğu sağladığı tespit edilmiştir.

Tablo 3.3. VERİ4 için farklı özniteliklerle sınıflandırma sonuçları

Öznitelik Yöntemleri	Öznitelik Sayısı	k parametresi	Sınıflandırma Başarısı (%)	Standart Sapma
Maksimum Değer	1	15	68	±5.322
Türev	6	3	68	±4.63
İntegral	2	6	60	±7.788
Ortalama, Basıklık, Standart Sapma, Çarpıklık	4	1	64	±6.02
Yükselme Zamanı	6	1	60	±7.35
Alt örnekleme yöntemi	7	8	74	±6.88

3.4. Sınıflandırma Bulguları

Sınıflandırma bulguları, Bölüm 3.3'de kullanılmasına karar verilen özniteliklerin farklı sınıflandırma algoritmalarına uygulanmasıyla elde edilen verilerden oluşmaktadır.

Farklı veri tabanları için çeşitli sınıflandırma algoritmaları ve yapılan çalışmalar kapsamında önerilen ikili karar ağacı yapısı uygulanmakta ve sonuçları karşılaştırılmaktadır. Böylece sınıflandırma sonuçlarıyla önerilen modelin başarısı ortaya konmaktadır. Ayrıca 4 veri tabanı için modelin eğitilip, test verisinin sınıflandırılmasındaki hız kıyaslaması yapılmaktadır. Bu şekilde her veri tabanındaki tüm sınıflandırma yöntemleri için hız performansı verilmektedir. Genel olarak yöntemler değerlendirildiğinde, Bayes sınıflandırıcının en yavaşlardan biri olduğu, DAA algoritmasının ise en hızlı olduğu gözükmektedir. Bu süre farkı algoritmaların yapısındaki hesaplamalardan kaynaklanmaktadır.

3.4.1. VERİ1 İçin Sınıflandırma Bulguları

VERİ1 12 sensörden elde edilen özniteliklerden oluşmaktadır. Her konsantrasyon değerine ait 12 öznitelik bütünüyle sınıflandırıcıya uygulanmak yerine, öznitelik alt küme seçme işleminden sonra uygulanmaktadır. Öznitelik seçme işlemi yapılan çalışmalarda bahsedildiği gibi AİS algoritmasıyla yapılmakta ve en başarılı sonucu veren özniteliklerin seçilmesi amaçlanmaktadır. Her algoritma için seçilen en iyi öznitelikler o sınıflandırma algoritmalarına uygulanmakta ve Tablo 3.4' de bu algoritmaların sınıflandırma sonuçları karşılaştırılmaktadır. Sonuçlar rastgele 30 farklı eğitim ve test verisinin modele uygulanmasıyla elde edilmektedir. 30 farklı eğitim ve test verisinin uygulanması sonucunda elde edilen belirlilik ve duyarlılık değeri uygulanan tüm yöntemler için Tablo 3.4' de özetlenmektedir.

Önerilen yöntemde kullanılan sınıflandırma yöntemleri, hangi sınıflandırıcıda hangi özniteliklerin kullanıldığı Tablo 3.5'de verilmektedir. 20 sınıfı ayırt etmek üzere 19 sınıflandırıcı kullanılmaktadır. Her düğümde kullanılan sınıflandırma yöntemleri model oluşturulurken en az öznitelikle, en hızlı sınıflandırmayı yapacak algoritma olarak seçilmektedir. Bu kapsamda model Tablo 3.5'deki gibi oluşturularak başarısı tespit edilmektedir.

Tablo 3.4. VERİ1 için farklı algoritmalarla sınıflandırma sonuçları

Sınıflandırma Yöntemleri	Öznitelik Sayısı	Parametre ve Öznitelikler	Çapraz Doğrulama Sınıflandırma Belirlilik Başarısı (%) Standart Sapma	Çapraz Doğrulama Sınıflandırma Duyarlılık Başarısı (%) Standart Sapma	Hız (sn)
Bayes	4	2, 4, 7, 11	91.368 ±3.717	91.595 ±17.004	0.457
k- EYK	2	k=4 2,11	93 ±3.619	93.636 ±12.645	0.102
DAA	3	2,10,11	95.333 ±4.536	95.66 ±9.003	0.098
Önerilen Yöntem	Tablo 3.5	Tablo 3.5	99.33 ±1.729	99.412 ±2.632	0.134

Tablo 3.4’de ayrıca her yöntemde kullanılan parametreler, öznitelikler ve uygulanan yöntemin test verisini değerlendirme hızları da verilmektedir. Bütün olarak ele alındığında önerilen yöntemin, belirlilik ve duyarlılık başarılarını yüksek oranda arttırdığı göze çarpmaktadır. Hız olarak çok geride olmaması sebebiyle gerçek uygulamalarda da rahatlıkla kullanılacak bir model oluşturulduğu gözlenmektedir. Önerilen yöntem en yakın sonuç DAA yöntemiyle elde edilmektedir. Özellikle bu yöntemin hızının çok iyi olduğu dikkat çekmektedir. Fakat program hızları arasında belirgin farklar olmadığı Tablo 3.4’de gözlenmektedir. DAA yöntemiyle özellikle birbirine çok yakın konsantrasyon değerleri olan 5 ve 10 ppm değerleri ile 240 ve 250 ppm değerini sınıflandırmada hatalar meydana geldiği gözlenmektedir.

Tablo 3.5. VERİ1 için önerilen ikili karar ağacı yapısında kullanılan sınıflandırıcılar, sınıflandırıcı parametreleri ve seçilen öznitelikler

Sınıflandırıcı	Sınıflandırma Algoritması	Kullanılan Parametreler	Öznitelik Sayısı	Öznitelikler
1. Sınıflandırıcı	DAA	Doğrusal	3	1, 2, 6
2. Sınıflandırıcı	k-EYK	k=4	1	2
3. Sınıflandırıcı	Bayes	Normal dağılım	1	2
4. Sınıflandırıcı	DVM	C=80, $\sigma=0.85$	1	3
5. Sınıflandırıcı	k-EYK	k=5	1	2
6. Sınıflandırıcı	DAA	Doğrusal	1	3
7. Sınıflandırıcı	DVM	C=100, $\sigma=1$	1	1
8. Sınıflandırıcı	DAA	doğrusal	4	1,4,7,10
9. Sınıflandırıcı	DVM	C=50, $\sigma=0.9$	1	2
10. Sınıflandırıcı	Bayes	Normal dağılım	2	7,9
11. Sınıflandırıcı	DAA	doğrusal	2	2,7
12. Sınıflandırıcı	k-EYK	k=5	1	1
13. Sınıflandırıcı	DVM	C=100, $\sigma=0.9$	1	1
14. Sınıflandırıcı	k-EYK	k=1	1	1
15. Sınıflandırıcı	DVM	C=100, $\sigma=1$	1	1
16. Sınıflandırıcı	DAA	doğrusal	1	1
17. Sınıflandırıcı	DAA	doğrusal	1	2
18. Sınıflandırıcı	DAA	doğrusal	1	3
19. Sınıflandırıcı	DAA	doğrusal	1	1

Önerilen yöntemde de yapılan sınıflandırma hatasının, düşük konsantrasyon değerleri olan 5 ve 10 ppm değerlerinde meydana geldiği Tablo 3.6’da gözlenmektedir. Bu konsantrasyon değerlerini ayırt ederken 30 denemede 4 yanılıyla sonuçlandığı, diğer yöntemlerle kıyaslandığında bunun çok daha az olduğu Tablo 3.4’den anlaşılmaktadır.

Tablo 3.5 incelendiğinde önerilen yöntemde seçilen öznelikler özellikle 1 ve 2. sensörlerden seçilmektedir. Bunun bir sebebi düğümdeki sınıflandırma algoritması öznelikleri sırayla denemekte ve % 100 başarıya ulaştıklarında öznelik seçme işlemini sonlandırmaktadır. Eğer sınıflandırma problemi kolaysa ilk öznelikte % 100 sınıflandırma başarı elde edilmektedir. Bu diğer özneliklerin aynı başarıyı sağlamayacağı anlamına gelmez. Bu yüzden 1. sensörden elde edilen özneliğin en çok kullanıldığı gözlenmektedir. Sınıflandırma problemi zor olan düğümler incelendiğinde 7. sensörün ayırt ediciliği göze çarpmaktadır.

Bu veri tabanı için önerilen karar ağacı yapısındaki modelin detayları Bölüm 2.5.6'da çalışmalar kısmında verilmektedir. Önerilen model çok fazla sınıf sayısı ve az veri olumsuzluklarında bile diğer yöntemlere göre daha başarılı sonuçlar vermektedir. En başarılı sonucu veren yöntem olan karar ağacı yapısında önerilen yöntem uygulandığında elde edilen karışıklık matrisi Tablo 3.6'da verilmektedir.

Tablo 3.7'de rakamlarla ifade edilen 20 sınıfın hangi konsantrasyon değerlerine karşılık geldiği Tablo 3.6'da verilmektedir. Tablo 3.6 ve Tablo 3.7'de verilen karışıklık matrisleri incelendiğinde sınıflandırma hatalarının, birbirine çok yakın küçük konsantrasyon değerleri için ortaya çıktığı gözlenmektedir. Bu küçük konsantrasyon değerlerini ayırt etmenin en etkili yolu problemi alt parçalara ayırarak, sorunlu bölgeyi kendi içinde ele almaktır. İkili karar ağacı tabanlı önerilen yöntem verileri alt parçalara bölerek sınıflandırdığı için en başarılı sonucu vermektedir. Diğer yöntemler ise sadece 5 ile 10 ppm değerlerini ayırt etmekte değil birbirine yakın diğer konsantrasyon sonuçlarını da ayırt etmekte zorlanmaktadır. Mesela diğer yöntemler 240 ile 250 ppm değerlerini veya 480 ile 500 ppm değerlerini ayırt etmekte zorlanmakta, hataların bu yakın değerleri ayırt ederken yapıldığı gözlenmektedir.

Tablo 3.6. VERİ1'de numaralandırılan sınıflara ait konsantrasyon değerleri

Sınıf No	Konsantrasyon Değeri Ppm	Sınıf No	Konsantrasyon Değeri ppm	Sınıf No	Konsantrasyon Değeri Ppm	Sınıf No	Konsantrasyon Değeri ppm
1	5	6	120	11	960	16	5000
2	10	7	240	12	1000	17	7750
3	25	8	250	13	1940	18	10000
4	50	9	480	14	2500	19	15550
5	100	10	500	15	3880	20	20000

Tablo 3.7. VERİ1 için önerilen sınıflandırma modeli uygulandığında elde edilen karışıklık matrisi

		ÖNGÖRÜLEN SINIF																		
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
G E R Ç E K S I N I F	1	26	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	2	0	30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	3	0	0	30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	5	0	0	0	0	30	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	6	0	0	0	0	0	30	0	0	0	0	0	0	0	0	0	0	0	0	0
	7	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0	0	0	0	0
	8	0	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0	0
	11	0	0	0	0	0	0	0	0	0	0	30	0	0	0	0	0	0	0	0
	12	0	0	0	0	0	0	0	0	0	0	0	30	0	0	0	0	0	0	0
	13	0	0	0	0	0	0	0	0	0	0	0	0	30	0	0	0	0	0	0
	14	0	0	0	0	0	0	0	0	0	0	0	0	0	30	0	0	0	0	0
	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30	0	0	0	0
	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30	0	0	0
	17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30	0	0
	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30	0
	19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	30
	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

3.4.2. VERİ2 İçin Sınıflandırma Bulguları

11 farklı koku örneğinden oluşan bu veri tabanı için, alt örnekleme özneliklerinin alt kümesini kullanarak elde edilen sınıflandırma sonuçları Tablo 3.8’de verilmektedir. Öznelik olarak bahsedildiği gibi en yüksek sınıflandırma başarısını sağlayan alt örnekleme yöntemiyle elde edilen öznelikler kullanılmaktadır. Bu öznelikler bütünüyle değil, öznelik seçme işleminden geçerek sınıflandırma algoritmasına gönderilmektedir. Öznelik seçme işlemi, Bölüm 2.4.5’de bahsedildiği gibi ardışıl ileri yönde seçim algoritmasıyla gerçekleştirilmektedir. Her yöntem için en başarılı sonucu veren öznelikler seçilmektedir. Her yöntemde kullanılan öznelik sayısı ve bu özneliklerin hangileri olduğu Tablo 3.8’de, önerilen yöntem için kullanılan sınıflandırma yöntemi, öznelik sayısı ve öznelikler Tablo 3.9’da verilmektedir. Birbirine çok yakın olmayan kokulardan oluşan bu veri tabanında önerilen yöntemle sınıflandırma başarısı % 100 yükseltilmektedir. Burada veri sayısı az olduğu için k katlı çapraz doğrulamanın bir türü olan birini dışarıda bırakma (leave one out) yöntemi eğitim verisine uygulanmakta ve her seferinde bir veri dışarıda bırakılarak sistem eğitilmekte, sistemin testi ise dışarıda bırakılan veri ile yapılmaktadır. Bunun sonucunda elde edilen her test verisinin doğru sınıflandırma başarısı

tüm yöntemler için Tablo 3.8’de çapraz doğrulama sınıflandırma başarısı olarak verilmektedir. 63 eğitim, 41 test verisinden oluşan bu veri tabanında çapraz doğrulama başarısı için model 63 kez her seferinde farklı eğitim kümesiyle eğitilip, bir veriyle test edilmekte ve önerilen yöntemle % 100 başarıya ulaşılmaktadır. Aynı şekilde önerilen yöntemle oluşturulan modele eğitim verisi uygulandığında yine sınıflandırma başarısı % 100 olarak elde edilmektedir. Hiç sisteme uygulanmayan 41 test verisi önerilen modele uygulandığında yine sınıflandırma başarısının % 100’e yükseltildiği Tablo 3.8’de gözükmemektedir. Önerilen yöntemde 11 kokuyu sınıflandırmak için 10 sınıflandırıcı kullanılmaktadır. Bu 10 sınıflandırıcıda kullanılan sınıflandırma algoritması, varsa bu algoritmaların parametreleri, öznitelikler ve sayıları Tablo 3.9’da verilmektedir. Bu tablo incelendiğinde en fazla özniteliğin 5. sınıflandırıcı olan 4 ve 5’den 6 ve 7’inci kokuları ayırt ederken kullanıldığı göze çarpmaktadır. Öznitelikleri incelerken de sensörlerin bu kokulara verdiği cevapların birbirine benzerliği dikkat çekmişti. Bu yüzden kullanılan diğer yöntemlerde en çok hatanın bu 4 kokunun ayırımında yapıldığı yine sonuçlardan gözlenmektedir. Önerilen yöntemde, sorunlu bölge kendi içinde ele alınıp o kokuları ayırt edecek en iyi özniteliklerin seçilmesine olanak sağlanmaktadır. Önerilen yöntemde kullanılan diğer sınıflandırıcılara bakıldığında 1 veya 2 özniteliğin o kokuları ayırt etmeye yettiği gözlenmektedir.

Tablo 3.8. VERİ2 için farklı algoritmalarla sınıflandırma sonuçları

Sınıflandırma Yöntemleri	Öznitelik Sayısı (Öznitelikler)	Parametreler	Test Verisi için Sınıflandırma Duyarlılık Başarısı (%)	Çapraz doğrulama Sınıflandırma Başarısı (%)	Hız (sn)
Bayes	4 (3,14,15,24)	Normal Dağılım	80.487	74.603	0.2051
k- EYK	3 (41,65,74)	k=3	93.83	88.42	0.0784
DAA	3 (17,34,45)		93.476	88.88	0.0643
Önerilen Yöntem	Tablo 3.9	Tablo 3.9	100	100	0.1885

Tablo 3.9’da kullanılan öznitelikler incelendiğinde, en çok kullanılan özniteliklerin 1, 2 ve 5. sensörlerden elde edildiği gözlenmektedir. Tablo 3. 10 ve 3.11’de eğitim ve test

verisi için önerilen yöntem uygulandığında elde edilen karışıklık matrisleri verilmektedir. İki veri grubu için de sınıflandırma başarısının %100'e ulaştığı gözlenmektedir.

Tablo 3.9. VERİ2 için önerilen ikili karar ağacı yapısında kullanılan sınıflandırıcılar, sınıflandırıcı parametreleri ve seçilen öznitelikler

Sınıflandırıcı	Öznitelik Sayısı	Kullanılan Öznitelikler	Sınıflandırma Algoritması	Parametreler
1	2	4, 40	DVM	$C=50, \sigma=0.15$
2	1	14	Bayes	Normal Dağılım
3	1	54, 65	DAA	Mahalanobis
4	1	4	k-EYK	$k=3$
5	4	11, 15, 44, 55	DAA	Mahalanobis
6	2	41,55	k-EYK	$k=1$
7	1	34	DVM	$C=75, \sigma=0.85$
8	1	1	DAA	Doğrusal
9	1	32	Bayes	Normal Dağılım
10	1	14	DVM	$C=100, \sigma=0.9$

Tablo 3.10. VERİ2 için önerilen yöntem kullanılarak elde edilen eğitim verisine ait karışıklık matrisi

		ÖNGÖRÜLEN SINIF											Belirlilik (%)
		1	2	3	4	5	6	7	8	9	10	11	
G E R Ç E K S I N I F	1	5	0	0	0	0	0	0	0	0	0	0	100
	2	0	6	0	0	0	0	0	0	0	0	0	100
	3	0	0	6	0	0	0	0	0	0	0	0	100
	4	0	0	0	6	0	0	0	0	0	0	0	100
	5	0	0	0	0	7	0	0	0	0	0	0	100
	6	0	0	0	0	0	6	0	0	0	0	0	100
	7	0	0	0	0	0	0	6	0	0	0	0	100
	8	0	0	0	0	0	0	0	4	0	0	0	100
	9	0	0	0	0	0	0	0	0	7	0	0	100
	10	0	0	0	0	0	0	0	0	0	6	0	100
	11	0	0	0	0	0	0	0	0	0	0	4	100
Duyarlılık (%)		100	100	100	100	100	100	100	100	100	100	100	100

3.4.3. VERİ3 İçin Sınıflandırma Bulguları

Farklı günlerde ölçüm yapılan balık tazeliği deneylerinde elde edilen verilerden oluşan VERİ3'e uygulanan farklı sınıflandırma yöntemlerinin başarıları Tablo 3.12'de görülmektedir. Birbirine benzer kokulardan oluştuğu için sınıflandırma işlemi daha zor

olan bu veri tabanında da önerilen yöntemin başarıyı yükselttiği gözükmektedir. VERİ2’de sınıflandırma için genellikle 1 veya 2 öznitelik kullanılırken, bu veri tabanında sınıflandırma başarısını arttırmak için öznitelik sayısını arttırmak gerekmektedir.

Tablo 3.11. VERİ2 için önerilen yöntem kullanıldığında test verisine ait karışıklık matrisi

		ÖNGÖRÜLEN SINIF											Belirlilik (%)
		1	2	3	4	5	6	7	8	9	10	11	
G E R Ç E K S I N I F	1	3	0	0	0	0	0	0	0	0	0	0	100
	2	0	4	0	0	0	0	0	0	0	0	0	100
	3	0	0	4	0	0	0	0	0	0	0	0	100
	4	0	0	0	4	0	0	0	0	0	0	0	100
	5	0	0	0	0	5	0	0	0	0	0	0	100
	6	0	0	0	0	0	4	0	0	0	0	0	100
	7	0	0	0	0	0	0	4	0	0	0	0	100
	8	0	0	0	0	0	0	0	2	0	0	0	100
	9	0	0	0	0	0	0	0	0	4	0	0	100
	10	0	0	0	0	0	0	0	0	0	4	0	100
	11	0	0	0	0	0	0	0	0	0	0	3	100
Duyarlılık (%)	100	100	100	100	100	100	100	100	100	100	100	100	100

Bu veri tabanı VERİ2’ye göre nispeten daha fazla veriden oluştuğu için, burada çapraz doğrulama yöntemi olarak 10 kat çapraz doğrulama kullanılmaktadır. Eğitim kümesi 110 veriden oluşurken, test kümesi 75 veriden oluşmaktadır. Eğitim kümesi 10 parçaya ayrılarak her seferinde 11 veri test ve 99 veri eğitim kümesinde kullanılarak model oluşturuldu ve 11 test verisiyle bu model test edildi. Böylelikle tüm eğitim verisi test verisi olarak uygulanarak çapraz doğrulama gerçekleştirildi. Bunun sonucunda elde edilen sınıflandırma başarısı ve standart sapması Tablo 3.12’de verilmektedir. Yine belirlenen modele 110 eğitim verisi ve 75 test verisi uygulandığında elde edilen sınıflandırma duyarlılık başarıları Tablo 3.12’de verilmektedir. Diğer yöntemlerle kıyaslandığında önerilen yöntemin sınıflandırma başarısını arttırdığı yine Tablo 3.12’den anlaşılmaktadır. Özellikle birbirine yakın kokuları ayırt etmekte diğer yöntemlere göre daha iyi olduğundan, diğer yöntemlerin sınıflandırma başarılarıyla arasında olan fark bu veri tabanında maksimum elde edilmektedir.

Tablo 3.12. VERİ3 için farklı algoritmalarla sınıflandırma sonuçları

Sınıflandırma Yöntemleri	Bayes	k- EYK	DAA	Önerilen Yöntem
Öznitelik Sayısı ve Öznitelikler	8 5,17,33,36,61, 63,65,78	3 16,43,63	8 14,20,27,55,57 59,63,64	Tablo 3.12
Parametreler	Normal dağılım	k=6	Mahalanobis	Tablo 3.12
Test Verisi için Sınıflandırma Duyarlılık Başarısı (%)	41.46	54.533	46.66	85.71
Çapraz Doğrulama Sınıflandırma Başarısı (%) ve Standart Sapma	62.22 ±17.31	66.363 ±18.704	55.454 ±17.902	84.539 ±12.161
Hız(sn)	0.2755	0.0447	0.0257	0.094

Tablo 3.12 hız bakımından incelendiğinde yine en hızlı yöntemin DAA olduğu gözlenmektedir. Ama aynı zamanda aradaki hız farklarının önemli boyutta olmadığı anlaşılmaktadır. Önerilen yönteme ait 6 sınıflandırıcıda kullanılan sınıflandırma algoritmaları, varsa bu algoritmalara ait seçilen parametreler, öznitelik sayıları ve öznitelikler Tablo 3.12’de verilmektedir. Bu tablo incelendiğinde en çok özniteliğin 4. düğümde kullanılan sınıflandırıcıda kullanıldığı göze çarpmaktadır. Bu sınıflandırıcıların yine en çok ayırt etmekte zorlanılan 1, 3, 5 ve 7 günlük balık kokularını sınıflandırmada kullanıldığı Şekil 2.20’den anlaşılmaktadır.

Tablo 3.13. VERİ3 için önerilen ikili karar ağacı yapısında kullanılan sınıflandırıcılar, sınıflandırıcı parametreleri ve seçilen öznitelikler

Sınıflandırıcı	1	2	3	4	5	6
Öznitelik Sayısı	3	3	7	7	5	5
Kullanılan Öznitelikler	63,64,65	56,62,63	2,4,9,37, 40,62,64	13,14,21, 22,37,38,73	1,64,71 73,74	4,27,34, 49,55
Sınıflandırma Algoritması	k-EYK	DVM	DAA	k-EYK	Bayes	DAA
Parametreler	k= 6 Öklid uzaklık	C=200 $\sigma=1$	-	k=3 Öklid uzaklık	Normal dağılım	-

Tablo 3.13 incelendiğinde, düğümlerde kullanılan sınıflandırıcılarda en çok kullanılan özneliklerin 7. sensör olan TGS 2602'den elde edildiği gözlenmektedir. Bu da TGS 2602 gaz sensörünün balık kokuları için seçiciliğinin yüksek olduğunu göstermektedir.

Tablo 3.14. VERİ3 için önerilen yöntem kullanılarak eğitim verisine ait karışıklık matrisi

		ÖNGÖRÜLEN SINIF							Belirlilik (%)
		1	2	3	4	5	6	7	
GERÇEK SINIF	1	14	0	0	0	0	0	0	100
	2	1	19	0	0	0	0	0	95
	3	0	0	8	1	0	0	0	88.88
	4	0	0	2	15	0	0	0	88.23
	5	0	0	0	2	15	0	0	88.23
	6	0	0	0	0	1	10	0	90.9
	7	0	0	0	0	0	0	11	100
Duyarlılık (%)		93.33	100	80	83.33	93.75	100	100	93.03
									92.91

Tablo 3.15 ve Tablo 3.16'da sırasıyla önerilen yöntem kullanıldığında elde edilen eğitim ve test verisi için elde edilen karışıklık matrisi verilmektedir. Yine bu tablolar detaylı incelendiğinde hataların özellikle 5 günlük veya 7 günlük diye tahmin edilen verilerde ortaya çıktığı gözlenmektedir.

Tablo 3.15. VERİ3 için önerilen yöntem kullanılarak test verisine ait karışıklık matrisi

		ÖNGÖRÜLEN SINIF							Belirlilik (%)
		1	2	3	4	5	6	7	
GERÇEK SINIF	1	10	0	0	0	0	0	0	100
	2	0	8	0	1	0	0	0	88.88
	3	0	1	6	1	1	0	0	66.67
	4	0	1	1	9	0	0	0	81.82
	5	0	0	0	3	7	0	0	70
	6	0	0	0	0	2	8	0	80
	7	0	0	0	0	0	0	13	100
Duyarlılık (%)		100	80	85.71	64.28	70	100	100	83.91
									85.71

Sadece bu veri tabanına benzer uygulamalar literatürde de kullanıldığı için, bu veri tabanı için literatürde yapılan çalışmalarla kıyaslama Tablo 3.16'da verilmektedir. Böylece çalışmanın literatürdeki yeri de ortaya konmaktadır. Tabloda kıyaslama, sınıf sayısı ve sınıflandırma başarısı için yapılmaktadır. Tablo 3.16 incelendiğinde literatürde kullanılan

sınıf sayısının çoğu uygulamada 5 ve 5'in altında olduğu gözükmektedir. Bu çalışmadan daha fazla sınıfa sahip Morina balık filetosunun 8 sınıfa ayrılmasında, sınıflandırma performansı %90 civarında elde edildi [163]. Ama bu başarı aynı zamanlı yapılan ölçümlerden elde edilmektedir. Yani eğitim ve test verisi aynı zamanda yapılan ölçümlerden elde edildi. Bu tez çalışmasında ise test ve eğitim verisinin elde edilme tarihleri arasında yaklaşık bir sene fark vardır. Bunun da başarıyı düşürücü olumsuz bir etkisi vardır. Bunlara ilaveten; filetonun büyüklüğü istavritle kıyaslandığında fileto daha büyük olup kesilmiş halde saklanmaktadır. Kesilmiş bir balığın yaydığı koku daha keskinleşeceğinden, fileto sınıflandırma problemi istavrit balığı sınıflandırma probleminden daha kolaydır. Literatürde, saklama ve uygulama koşulları bu tez çalışmasındaki veri tabanlarıyla birebir uyuşan çalışma bulunmamaktadır. Bundan dolayı literatürdeki sonuçlar ile bu çalışmada elde edilen sonuçlar karşılaştırılmamaktadır.

Tablo 3.16. Önerilen yöntem ve literatürdeki yöntemlerin karşılaştırılması

Balık Türü	Sınıf Sayısı	Saklama Koşulları	Başarı	Literatür
Atlantik Somonu	2	+4° C	% 95	[162]
Sardalya	3	+4° C	% 96.88	[138]
Sardalya	3	+4° C	% 100	[161]
Deniz Çipurası	3	+4° C	% 100	[160]
Tatlısu Kefali	3	+4° C	% 87.5	[141]
Fas Sardalyası	5	+4° C	% 88.3	[126]
Morina balığı filetosu	8	+4° C	%90.5	[163]
İstavrit	7	+4° C ve buz kalıpları	% 85.71	Önerilen yöntem

3.4.4. VERİ4 İçin Sınıflandırma Bulguları

3 farklı balık kokusundan oluşan VERİ4, birbirine benzer kokulardan oluştuğu için zor ama az sayıda sınıf olduğu için VERİ3'e göre sınıflandırması daha kolay bir veri tabanıdır. Bu veri tabanında veri sayısından dolayı 4 kat çapraz doğrulama kullanılmaktadır. Toplamda 129 verinin 79'u eğitim verisi olarak kullanılırken, 50'si test verisi olarak kullanılmaktadır. 79 eğitim verisi 4 parçaya bölünmüş, biri 19 olmak üzere her 20 veri test için bir kez kullanılarak kalan 59 veri ile model oluşturulmaktadır. Böylelikle tüm eğitim verisinin test olarak uygulanması sağlanmaktadır. Bunun sonucunda elde edilen sınıflandırma başarısı ve standart sapması Tablo 3.17'de verilmektedir. Yine

aynı tabloda tüm yöntemlerde kullanılan parametreler, öznitelik sayısı ve öznitelikler gösterilmektedir. Bu tablo incelendiğinde önerilen yöntemin sınıflandırma başarısını tüm veriler için arttırdığı gözlenmektedir. Önerilen yönteme ait 2 sınıflandırıcıda kullanılan algoritmalar, varsa bu algoritmaların parametreleri, öznitelik sayısı ve öznitelikler Tablo 3.18’de verilmektedir. Burada diğer veri tabanlarından farklı olarak tek tip algoritmanın karar ağacı yapısında uygulanmasıyla en yüksek başarının elde edildiği görülmektedir. Karar ağacı yapısında kullanılacak sınıflandırma algoritmasını tüm veri tabanlarında olduğu gibi, en az sayıda öznitelikle ve en hızlı sınıflandırmayı sağlayacak algoritma olacak şekilde seçilmektedir. Tablo 3.18 incelendiğinde, karar ağacı yapısında sadece DAA algoritması sınıflandırıcı olarak seçilmektedir. Diğer yöntemlerden bazılarının da bu başarıyı sağlamasına rağmen, en hızlı ve en az öznitelikle sınıflandırma yapma olanağını sunduğu için bu yöntem seçilmiştir.

Tablo 3.17. VERİ4 için farklı algoritmalarla sınıflandırma sonuçları

Sınıflandırma Yöntemleri	Bayes Sınıflandırıcı	k- EYK	DAA	Önerilen Yöntem
Öznitelik Sayısı Ve Öznitelikler	5 (7,37,44,47,56)	3 (27,37,49)	6 (12,23,24,34,45,52)	Tablo 3.16
Parametreler	Normal Dağılım	k=1	Doğrusal	Tablo 3.16
Test Verisi için Sınıflandırma Duyarlılık Başarısı (%)	86.25	78.27	72.8	95.73
Çapraz Doğrulama Sınıflandırma Başarısı (%) ve Standart Sapma	85.73 ±10.8	88.75 ±2.5	80.32 ±14.37	94.75 ±4.11
Hız (sn)	0.191	0.063	0.048	0.054

Tablo 3.18. VERİ4 için önerilen ikili karar ağacı yapısında kullanılan sınıflandırıcılar, sınıflandırıcı parametreleri ve seçilen öznitelikler

Sınıflandırıcı	1. Sınıflandırıcı	2. Sınıflandırıcı
Öznitelik Sayısı	13	13
Kullanılan Öznitelikler	5,6,7,9,23,24,25,28 46,52,54,55,56	1,2,10,15,23,26,27,28 29,40,44,49,51
Sınıflandırma Algoritması	DAA	DAA
Parametreler	Mahalanobis	Mahalanobis

Tablo 3.18’de kullanılan öz nitelikler incelendiğinde 4. sensör olan TGS 826 gaz sensörünün farklı balık kokuları için en yüksek seçiciliğe sahip olduğu gözlenmektedir. Tablo 3.19 ve 3.20’de önerilen yöntem eğitim ve test verisi uygulandığında elde edilen karışıklık matrisleri verilmektedir. Bu tablolar incelendiğinde, eğer tahmin edilen balık kokusu mezgit ve istavrit ise bunun %100 doğrulukla tahmin edildiği, eğer tahmin edilen koku hamsi kokusu ise bunun hamsi kokusu olma ihtimalinin % 75.21 olduğu gözlenmektedir. Ayrıca bu tablolardan istavrit ile mezgitin birbirinden rahatlıkla ayrılabilceği, ama hamsi ile diğer balıkların kokularını sınıflandırmada hataların meydana geldiği de görülmektedir.

Tablo 3.19. VERİ4 eğitim verisi için önerilen yöntem a ait karışıklık matrisi

		Öngörülen Sınıf			Belirlilik (%)
		İstavrit	Hamsi	Mezgit	
Doğru Sınıf	İstavrit	27	0	0	100
	Hamsi	0	27	0	100
	Mezgit	0	0	25	100
Duyarlılık (%)		100	100	100	100

Tablo 3.20. VERİ4 test verisi için önerilen yöntem a ait karışıklık matrisi

		Öngörülen Sınıf			Belirlilik (%)
		İstavrit	Hamsi	Mezgit	
Doğru Sınıf	İstavrit	15	1	0	93.75
	Hamsi	0	18	0	100
	Mezgit	0	2	14	87.5
Duyarlılık (%)		100	85.71	100	93.75
					95.23

4. SONUÇLAR

Son yıllarda kimyasal gazları ayırt etme, sınıflandırma ve algılama, e-burun uygulama alanlarının genişlemesinden dolayı önem kazanmakta, e-burunla ilgili yapılan çalışmaları hızlandırmaktadır. Bu tez çalışmasında gün geçtikçe kullanım alanı ve önemi artan e-burunların problemleri üzerinde durulmakta ve bu problemlere çözüm önerileri getirilmektedir. Bu kapsamdaki çalışmayla elde edilen sonuçlar aşağıda verilmektedir.

1. İşaret ön işleme biriminde uygulanan ön işleme işlemlerinin, metal oksit gaz sensörlerin en büyük problemlerinden biri olan sensör cevaplarında meydana gelen kaymaları azalttığı gözlemlendi. Bu aşamada, literatürden farklı olarak taşıyıcı gaz sinyali örnek koku sinyalinden çıkartılarak fark sinyali örüntü tanıma birimine uygulandı. Bunun sonucunda sensör kaymalarının azaldığı tespit edildi. Sensör kaymalarının sınıflandırma performansı üzerinde olumsuz etkileri olduğu için, bu çalışma kapsamında uygulanan işaret ön işleme işleminin sınıflandırma performansını arttırdığı söylenebilir.
2. E-burunun önemli birimlerinden biri olan öznitelik çıkarma biriminde; kullanımı yaygın olmayan alt örnekleme yönteminin, bu tez kapsamında önerilen hibrit algoritmayla birleşmesi sonucu, sınıflandırma performansını arttırdığı gözlenmektedir. Bunun sebeplerinden biri; alt örnekleme yönteminin işaretin bütünüyle ilgili bilgiyi taşıması, işaretle ilgili bilgi kaybının minimum olması şeklinde ifade edilebilir.
3. Öznitelik çıkarma yöntemleri genel olarak değerlendirildiğinde, sürekli durum parametrelerinin öznitelik olarak kullanılmasının işaret hakkında yeterli veriyi taşımadığı, geçici durum parametrelerinden de faydalanılması gerektiği sonucuna varılmaktadır. Geçici durum parametrelerinin kullanılması durumunda sınıflandırma performanslarının arttığı gözlenmektedir.
4. Yine e-burunun önemli biriminden olan sınıflandırma birimi için önerilen hibrit sınıflandırma yöntemiyle, elektronik burun verilerinin sınıflandırma başarısının arttığı gözlenmektedir. Özellikle önerilen yöntemle sınıflandırma başarısındaki artışın birbirine yakın kokuları içeren veri tabanlarında çok daha fazla olduğu gözlenmektedir. Önerilen yöntemin doğası gereği problemi parçalara ayırarak çözmesinden dolayı, problemleri bölgelere odaklanmayı sağlamaktadır. Böylece

problemlı blgeyi en iyi sınıflandıracak z niteliklerin ve algoritmaların seilmesine olanak saęlamaktadır.

5. nerilen ikili karar aęacı tabanlı sınıflandırma ynteminin saęladığı avantajlardan biri karar aęacı yapısındaki sınıflandırıcılarda kullanılan z nitelikler her sınıflandırıcının ayırdığı veriye gre deęişip algoritmaya esneklik saęlamaktadır. Bunun da sınıflandırma performansını arttırdığı gzlenmektedir.
6. nerilen sınıflandırma ynteminin saęladığı avantajlardan bir dięeri ise karar aęacı yapısındaki dęmlerde kullanılan yntemlerin her sınıflandırıcının ayırdığı veriye gre deęişme olanağına sahip olup algoritmaya esneklik saęlamasıdır. Bu ikili karar aęacı tabanlı sınıflandırma yntemi tm veri tabanlarına uygulandıęında, sınıflandırma performansını arttırdığı gzlenmektedir. Bunlardan en dikkat ekeni ise VERİ3 iin elde edilen sınıflandırma performans deęerleridir. Bu veri tabanına nerilen yntem uygulandıęında sınıflandırıcı başarısı test verisi iin % 54.533'lerden % 85.71'e ıkarken, doęrulama verisi iin başarı oranının % 66.36'dan %84.539'a ıkmaktadır.
7. Balık veritabanı iin literatrde balık tazelięi tespitinde sisteme uygulanan balıklar genellikle +4°C de saklanırken, bu alıřmada balıkının saklama kořulları gz nnde bulundurularak, daha iyi korunan balıkların tazelięi ayırt edilmiřtir. Daha iyi korunan balık kokularının oluřturduęu veri tabanı daha zor olmakla birlikte gerek uygulamayı yansıtmaktadır. nk balık tazelięinin son tketickiye ulařma kořulları dikkate alındıęında alıřmanın gerekilięi arttırılmıř olmaktadır. Bu zor sınıflandırma probleminde dahi nerilen yntemin başarıyı arttırdığı gzlenmektedir.
8. Balık veri tabanında eęitim ve test verilerinin e-burun deney dzeneęinde elde edilmesinde yaklaşık 1 yıl fark vardır. Bu da kurulan e-burun deney dzeneęinin 1 yıl sonrasında bile herhangi bir ekstra kalibrasyon veya n iřlem gerektirmeden başarılı sınıflandırma performansının elde edilebildięini gstermektedir. Buradan zellikle, nerilen iřaret n iřleme ařamasının ve hibrit z nitelik seme ve sınıflandırma ynteminin tekrar edilebilirlięi ve dayanıklılıęı kanıtlanmaktadır.

9. Metal oksit gaz sensörlerinin farklı veri tabanları için davranışları bu çalışma kapsamında detaylı incelenmektedir. Bu incelemelerin sonuçlarından biri sensör hassasiyetleri farklı veri tabanları için incelendiğinde TGS 826, TGS 2104 ve TGS 2602 sensörlerinin hassasiyetlerinin tüm veri tabanındaki veriler için yüksek olduğunu göstermektedir. Yani bu sensörlerin genel kokuları algılamakta iyi olduğu söylenebilir. Genel amaçlı algılama yapılacak bir e-burun tasarımı bu sensörlerin kullanılması önerilebilir.
10. Bu çalışmada kullanılan gaz sensörleri tüm veri tabanları için seçicilikleri açısından incelendiklerinde, her veri tabanında farklı sensörlerin seçiciliklerinin yüksek olduğu gözlenmektedir. VERİ2'deki farklı kokuları ayırt etmekte TGS 880, 825 ve 2610 sensörlerinin seçiciliklerinin yüksek olduğu, en çok bu sensör işaretlerinden çıkarılan özneliklerin kullanılmasından anlaşılmaktadır. Bu veri tabanı için hassasiyeti yüksek olan sensörlerin, seçiciliklerinin çok da yüksek olmadığı anlaşılmaktadır. Dolayısıyla sensör seçiminde, kullanım amacı önem kazanmaktadır. Önemli olan farklı gazların miktarlarının tespitiyse hassasiyeti yüksek olan sensörler tercih edilmeliyken, amaç farklı kokuları birbirinden ayırt etmekse, seçiciliği yüksek olan sensörler tercih edilmelidir. Ama genel uygulamalarda gazın miktarıyla birlikte hangi gaz olduğunun da önemi yüksektir. Bu yüzden gaz sensörleri tercihinde hem seçiciliği hem de hassasiyeti yüksek sensör dizisi kullanılmalıdır. İkisini aynı anda barındıran sensör bulunmadığı takdirde farklı özellikleri iyi olan sensörler tıpkı bu çalışmada olduğu gibi bir arada kullanılabilir. Bu tez çalışması kapsamında kurulan genel amaçlı koku tanıma sisteminde kullanılan sensörlerin doğru seçildiği bu sonuçlardan anlaşılmaktadır.
11. VERİ3'de ise özel bir koku grubundan oluşan veriler ele alınmakta ve bu veri grubu için seçiciliği en yüksek sensörün TGS 2602 gaz sensörü olduğu sonucuna varılmaktadır. TGS 2602 sensörünün hassasiyetinin de yüksek olduğu gözlenmektedir. Buradan varılacak sonuç, özel veri grupları için sadece o veri grubuna özel sensörler kullanılarak sensör sayısının az tutulabileceği ve böylece e-burun maliyetinin düşürülebileceğidir. Ayrıca daha az gaz sensöründen elde edilen verilerde hesaplama maliyetinin düşeceği ve sistemin hızlanacağı söylenebilir.

12. VERÍ4 için hangi sensörün seçiciliğinin yüksek olduğu incelendiğinde TGS 826 sensörü göze çarpmaktadır. Bu sensörün farklı balıkları algılamakta ve ayırt etmekte iyi olduğu sensör cevaplarından ve kullanılan özniteliklerden anlaşılmaktadır. Buradan da, özel uygulamalar için elde edilen veri grupları için bir sensörün diğerlerinden daha fazla ortaya çıktığı sonucuna varılmaktadır.
13. Hibrit yöntemde kullanılan sınıflandırıcılar incelendiğinde, içlerinden en hızlısının DAA yöntemi, en yavaşının da Bayes sınıflandırma yöntemi olduğu sonucuna varılmaktadır. Özellikle sorunlu bölgeleri sınıflandırmada ise kullanılan yöntemin başarısının verinin yapısına göre değişkenlik gösterdiğini, ama DAA analizinin genel olarak balık veri grupları için daha iyi sınıflandırma performansı sergilediği anlaşılmaktadır.

Tez çalışmasında koku tanıma sistemindeki problemlerin iyileştirilmesini hedefleyen yeni sinyal ön işleme ve örüntü tanıma tasarımı gerçekleştirilmiştir. Önerilen yöntem, literatürde ilk olarak, sinyal ön işleme aşamasında aynı e-burundan elde edilen fark sinyalini kullanarak sensör kaymalarının etkisini azaltmaktadır. Aynı zamanda sınıflandırılması zor veri grubu içinde performansı yüksek bir sınıflandırıcı modeli önerilmektedir. Çalışmalarda önerilen yöntemlerin uygulamaları tümüyle MATLAB ortamında geliştirilmiştir.

5. ÖNERİLER

E-burun ile ilgili yapılan çalışmaların özellikle 2000’li yıllarda ivmelendiği gözlenmektedir. Günümüzde bile tam anlaşılammış duyu organlarımızdan esinlenerek ortaya çıkan e-burun sistemleri gelişmeye açık bir konudur. Hem donanımsal hem de yazılımsal gelişmeye ihtiyaç duyan bu konu üzerinde gerçekleştirdiğimiz bu çalışma kapsamında aşağıdaki önerilerde bulunulabilir.

1. E-burun sisteminin ilk ayağı olan ve günümüzde çalışmaları devam eden sensörler için yeni teknolojiler kullanılabilir ve sensörler nano teknolojinin daha da gelişmesiyle biyolojik koku alma sistemini birebir taklit edebilir seviyeye getirilebilir.
2. Henüz yeni teknoloji sensörlerinin maliyetlerinin pahalı olması, ticari yaygınlığının olmaması ve ideal sensörün bulunamamış olması nedeniyle, mevcut kullanılan sensörlerden alınan verinin yüksek verimlilikte kullanılması için örüntü tanıma kısmında yenilikler yapılabilir.
3. Önerilen işaret ön işleme adımı ve hibrit sınıflandırma yöntemi gerçek zamanlı bir uygulamaya ve hareketli bir e-burun sistemine uygulanabilir.
4. Bu çalışma kapsamında, kapalı sistem koku örnekleme yapan veriye uygulanması önerilen yöntemler, açık sistem koku örnekleme yapan veriye uygulanabilir ve yöntemlerin uygulama alanı genişletilebilir.
5. Tezde öznitelik çıkarma için önerilen alt örnekleme yöntemiyle bir kez model kurulduktan sonra, örnekleme aralığı belirlenmektedir. Gerçek zamanlı uygulamalarda test verisinin belirlenen örnekleme aralığı boyunca örneklenmesini sağlayıp örüntü tanıma kısmında az veri kullanarak işlemler hızlandırılabilir. Böylece gerçek zamanlı uygulamaların öncelikli sorunu hız olduğu için bu tez çalışmasında önerilen öznitelik çıkarma yöntemi ile sistemin hızı rahatlıkla artırılabilir.
6. Hızın çok önem kazandığı bir uygulamada, önerilen hibrit yöntem sadece sınıflandırılması problemlı bölgelerde kullanılarak hem sistem hızı hem de sistemin sınıflandırma performansı artırılabilir.
7. Önerilen yöntem gereği, sensörler incelendiğinde istavrit balığının tazelik tespitinde TGS 2602 gaz sensörü öne çıkmaktaydı. Sadece bu sensör ve önerilen

hibrit yöntem kullanılarak balık tazeliğini tespit edecek hareketli ve küçük bir ticari ürün üretilebilir.

8. Farklı balık kokularını ayırt etmekte öne çıkan TGS 826 gaz sensörü 5. maddede önerilen sisteme ilave edilip hangi balığın kaç günlük olduğunu tespit eden bir ticari ürün gerçekleştirilebilir.
9. Genel bir koku tanıma sistemi gerçekleştirilip, uygulanacak özel veri grupları için sınıflandırma modeli bir kez oluşturulduktan sonra, her sensörün etkinliğine göre sensörleri katsayıyla çarparak, genel amaçlı koku tanıma sistemi özelleştirilebilir.

6. KAYNAKLAR

1. Pearce, T.C., Schiffmann, S. S., Nagle, H.T. ve Gardner, J.W., Handbook of Machine Olfaction, Second Edition, WILEY-VCH, Almanya, 2003.
2. Saraoğlu, H.M., Elektronik Burun Teknolojisi ve Uygulama Alanları, Akademik Bilişim'08, Şubat 2008, Çanakkale, Bildiriler Kitabı: 419-427.
3. Bhattacharyya, N., Tudu, B, Metla, A, Jana, A. ve Bandyopadhyay, R., Incremental PNN Classifier for A Versatile Electronic Nose, 3rd International Conference on Sensing Technology, Kasım 2008, Tainan, Taiwan, Proceedings: 242 - 247.
4. Tudu, B., Bhattacharyya, N., Kow, B. ve Bandyopadhyay, R., Comparison of Multivariate Normalization Techniques as Applied To Electronic Nose Based Pattern Classification for Black Tea, 3rd International Conference on Sensing Technology, Kasım 2008, Tainan, Taiwan, Proceedings: 254 - 258.
5. Bhattacharyya, N., Bandyopadhyay, R., Bhuyan, M., Tudu, B., Ghosh, D. ve Jana, A., Electronic Nose for Black Tea Classification and Correlation of Measurements with Tea Taster Marks, Instrumentation and Measurement, IEEE Transactions on, 57, 7 (2008) 1313-1321.
6. Bhattacharyya, N, Tudu, B., Bandyopadhyay, R., Bhuyan, M. ve Mudi, R., Aroma Characterization of Orthodox Black Tea with Electronic Nose, IEEE Region 10 Conference, Kasım 2004, Chiang Mai, Proceedings: 427 - 430.
7. Cunshe, C., Xiaojuan, L. ve Huimei, Y., Quality Assessment of Beef Based of Computer Vision and Electronic Nose, Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing, SNPD 2007, Temmuz - Ağustos 2007, Qingdao, Proceedings: 627 - 631.
8. Pornpanomchai, C. ve Suthamsmai, N., Beer Classification by Electronic Nose, International Conference on Wavelet Analysis and Pattern Recognition, ICWAPR '08, Ağustos 2008, Hong Kong, Proceedings: 333 - 338.
9. Mensing, J., Kladsomboon, S. ve Kerdcharoen, T., Optical Gas Sensor Based on Mgtp Thin Film for The Detection of Alcohol Vapors, 5th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, Mayıs 2008, Krabi, Proceedings: 849 - 852.
10. Brezmes, J., Ma Fructuoso, L. L., Llobet, E., Vilanova, X., Recasens, I., Orts, J., Saiz, G. ve Correig, X., Evaluation of An Electronic Nose To Assess Fruit Ripeness, IEEE Sensors Journal, 5,1 (2005) 97-108.

11. Di Natale, C., Macagnano, A., Mantini, A., Davide, F., D'Amico, A., Paolesse, R., Boschi, T., Faccio, M. ve Ferri, G., Advances in Food Analysis by Electronic Nose, IEEE International Symposium on Industrial Electronics, ISIE '97, Temmuz 1997, Guimaraes, Portugal, Proceedings: 122 - 127.
12. Di Natale, C., Macagnano, A., Paolesse, R., Tarizzo, E., Amico, A. D., Davide, F., Boschi, T., Faccio, M., Ferri, G., Sinesio, F., Bucarelli, F. M., Moneta, E. ve Quaglia, G. B., A Comparison Between An Electronic Nose and Human Olfaction in A Selected Case Study, Solid State Sensors and Actuators, International Conference on TRANSDUCERS 97, Haziran 1997, Chicago, Proceedings: 1335-1338.
13. Falasconi, M., Pardo, P., Sberveglieri, G., Ricco, I., Nardini, F., Delia Torre, M. ve Bresciani, A., The Novel EOS835 Electronic Nose Sniffs Out the Italian Espresso Coffee Quality, IEEE Sensors, Ekim 2003, Toronto, Canada, Proceedings: 26 -29.
14. Shin, H.W., Llobet, E., Gardner, J.W., Hines, E.L., ve Dow, C.S., Classification of The Strain and Growth Phase of Cyanobacteria in Potable Water Using An Electronic Nose System, IEE Proceedings Science, Measurement and Technology, 147, 4 (2000) 158-164.
15. Geoffrey, J.G., Chan, A.D.C. ve Goubran, R.A., An Investigation into The Suitability of Using Three Electronic Nose Instruments for The Detection and Discrimination of Bacteria Types, 28th IEEE EMBS Annual International Conference, Eylül 2006, New York City, USA, Proceedings: 1850 - 1853.
16. Panigrahi, S., Chang, Y., Khot, L. R., Glower, J. ve Logue, C.M., Integrated Electronic Nose System for Detection of Salmonella Contamination in Meat, IEEE Sensors Applications Symposium (SAS), Şubat 2008, Atlanta, GA, Proceedings: 85 - 88.
17. Chan, C.C., Ozkaynak, H., Spengler, J. D. ve Sheldon, L., Driver Exposure To Volatile Organic-Compounds, CO, Ozone, and NO2 Under Different Driving Conditions, Environ. Sci. Technol., 25 (1991) 964.
18. Leung, P.L. ve Harrison, R.M., Roadside and In-Vehicle Concentrations of Monoaromatic Hydrocarbons, Atmospheric Environment, 33 (1999) 191.
19. Ryan, M.A., Homer, M.L., Buehler, M.G., Manatt, K.S., Zee, F. ve Graf, J., Monitoring The Air Quality in A Closed Chamber Using An Electronic Nose, 27th International Conference on Environmental Systems, Society of Automotive Engineers, Temmuz 1997, Lake Tahoe, Nevada, Proceedings: 84 – 97.
20. Ryan, M.A., Homer, M.L., Buehler, M.G., Manatt, K.S., Lau, B., Karmon, D. ve Jackson, S., Monitoring Space Shuttle Air for Selected Contaminants Using An Electronic Nose, 28th International Conference on Environmental Systems, Society of Automotive Engineers, Temmuz 1998, Danvers, Massachusetts, USA, Proceedings: 98 - 102.

21. Ryan, M.A., Homer, M.L., Zhou, H., Manatt, K.S., Ryan, V.S. ve Jackson, S.P., Operation of An Electronic Nose Aboard The Space Shuttle and Directions for Research for A Second Generation Device, Proceedings of The 30th International Conference on Environmental Systems, Society of Automotive Engineers, Temmuz 2005, Toulouse, France, Proceedings: 259.
22. Nix, M.B., Homer, M.L., Kisor, A.K., Soler, J., Torres, J., Mannat, K., Jewell, A. ve Ryan, M.A., Sniffing Out Problems for Humans in Space, IEEE Potentials, 26, 4 (2007) 18 - 24.
23. Kusumoputro, B. ve Rivai, M., Discrimination of Fragrance Odor by Arrayed Quartz Resonator and A Neural Network, International Conference on Computational Intelligence and Multimedia Applications, Ocak 1998, Gippsland, Victoria, Australia, Proceedings: 264 - 269.
24. Cao, Z., Lin, H.G., Wang, B.F., Xu, D. ve Yu, R. Q., A Perfume Odor-Sensing System Using An Array of Piezoelectric Crystal Sensors with Plasticized PVC Coatings, Fresenius Journal of Analytical Chemistry, 355, 2 (1996) 194-199.
25. Hosseini, G.H., Luo, D., Liu., H. ve Xu, G., Intelligent Processing of E-Nose Information for Fish Freshness Assessment, 3rd International Conference on Intelligent Sensors, Sensor Networks and Information, ISSNIP, Aralık 2007, Melbourne, Australia, Proceedings: 173 - 177.
26. Kurup, P.U., An Electronic Nose for Detecting Hazardous Chemicals and Explosives, IEEE Conference on Technologies for Homeland Security, Mayıs 2008, Waltham, MA, Proceedings: 144 - 149.
27. Men, H., Li, X., Wang, J. ve Jing, G., Applies of Neural Networks To Identify Gases Based on Electronic Nose, IEEE International Conference on Control and Automation, Haziran 2007, Waltham, MA, Proceedings: 2699 - 2704.
28. Morsi, I., Electronic Noses for Monitoring Environmental Pollution and Building Regression Model, Industrial Electronics, 34th Annual Conference of IEEE, Kasım 2008, Orlando, FL, Proceedings: 1730 - 1735.
29. Nimsuk, N. ve Nakamoto, T., Study of Odor Classification in Dynamically Changing Concentration Using QCM Sensor Array and Short-Time Fourier Transform International Solid-State Sensors, Actuators and Microsystems Conference, Transducers, Haziran 2007, Lyon, Proceedings: 2469 - 2472.
30. Pan, L., Liu, R., Peng, S., Chai, Y. ve Yang, S.X., An Wireless Electronic Nose Network for Odours Around Livestock Farms, International Conference on 14th Mechatronics and Machine Vision in Practice, Aralık 2007, Xiamen, Proceedings: 211 - 216.

31. Charles, R., Krupin, Y., Holstead, J., Trcka, A., Pan, L. ve Yang, S.X., Development of A New Electronic Nose for Odour Measurement Utilizing Wireless Sensor Networks, IEEE International Conference on Networking, Sensing and Control, Nisan 2007, London, UK, Proceedings: 455 - 459.
32. Pan, L., Liu, R., Peng, S., Yang, S.X. ve Gregori, S., Real-Time Monitoring System for Odours Around Livestock Farms, IEEE International Conference on Networking, Sensing and Control, Nisan 2007, London, UK, Proceedings: 883 -888.
33. Cai, J. ve Levy, D. C., Using Stationary Electronic Noses Network To Locate Dynamic Odour Source Position, IEEE International Conference on Integration Technology, Mart 2007, Shenzhen, China, Proceedings: 793 - 798.
34. Kim, Y.W., Cho, J.H. ve Jeon, G.J., An Intelligent Wireless Electronic Nose Node for Monitoring Gas Mixtures Using Neuro-Fuzzy Networks Implemented on A Microcontroller, IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, Haziran 2007, Ostuni, Italy, Proceedings: 100 - 104.
35. Zhang, X. ve Zhang, M., Design of A Bionic Electronic Nose for Robot, International Colloquium on Computing, Communication, Control, and Management, Ağustos 2008, Guangzhou, Proceedings: 18 - 23.
36. Haeringer, D. ve Goschnick, J., Characterization of Smelling Contaminations on Textiles Using A Gradient Micro Array as An Electronic Nose, International Solid-State Sensors, Actuators and Microsystems Conference, Transducers, Haziran 2007, Lyon, Proceedings: 2477 - 2480.
37. Nakamoto, T., Nimsuk, N., Wyszynski, B., Takushima, H., Kinoshita, M. ve Cho, N., Reproduction of Scent and Video at Remote Site Using Odor Sensing System and Olfactory Display Together with Camera, Sensors IEEE, Ekim 2008, Lecce, Proceedings: 799 - 802.
38. Nakamoto, T. ve Nakama, T., Odor Recorder Using Mass Spectrometry and Large-Scale Data Sensors, 2007 IEEE, Ekim 2007, Atlanta, GA, Proceedings: 174 - 177.
39. Hu, J., Application of PCA Method on Pest Information Detection of Electronic Nose, IEEE International Conference on Information Acquisition, Ağustos 2006, Weihai, Shandong, China, Proceedings: 1465 - 1468.
40. Ye, S. ve Hu, J., Insect Herbivory Information Detection by Principal Component Analysis on Electronic Nose System, International Conference on Neural Networks and Brain, Ekim 2005, Beijing, Proceedings: 401 - 404.
41. Wongchoosuk, C., Lutz, M. ve Kerdcharoen, T., Correction of Humidity Effect for Detection of Human Body Odor, 5th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, Mayıs 2008, Krabi, Proceedings: 845 - 848.

42. Tello, A.W., Karg, H. K. ve Pady, S. P., Detection of Humans Buried in Rubble: An Electronic Nose To Detect Human Body Odor, IEEE Second Joint EMBS/BMES Conference, Ekim 2002, Houston, USA, Proceedings III: 1811-1812.
43. www2.it.lut.fi/kurssit/03-04/010970000/seminars/Korotkaya.pdf Biometric Person Authentication: Odor. 29 Ekim 2003.
44. Saraoğlu, H.M. ve Çakmak, N., Nefes Kokusundan Hastalık Tanısı İçin Nefes Neminin Qcm Sensörlere Etkisinin Yapay Sinir Ağı ile İncelenmesi, Akademik Bilişim'08, Şubat 2008, Çanakkale, Bildiriler Kitabı: 435 - 441.
45. Keller, P.E., Electronic Noses and Their Applications, IEEE Technical Applications Conference and Workshops Northcon95, Ekim 1995, Portland, OR, Proceedings: 116.
46. Wang, P., Chen, X., Xu, F., Lu, D., Cai, W., Ying, K., Wang, Y. ve Hu, Y., Development of Electronic Nose for Diagnosis of Lung Cancer At Early Stage, International Conference on Information Technology and Application in Biomedicine, in Conjunction with The 2nd International Symposium & Summer School on Biomedical and Health Engineering, Mayıs 2008, Shenzhen, China, Proceedings: 588 - 591.
47. Assad, O. ve Haick, H., Chemically Sensitive Field Effect Transistors of Oxide-Free Silicon Nanowires - Towards Detection of Volatile Biomarkers of Cancer, IEEE International Symposium on Industrial Electronics, Temmuz 2008, Cambridge, Proceedings: 2040 - 2044.
48. Blatt, R., Bonarini, A., Calabro, E., Torre, M.D., Matteucci, M. ve Pastorino, U., Lung Cancer Identification by An Electronic Nose Based on MOS Sensors Array, International Joint Conference on Neural Networks, Ağustos 2007, Orlando, Florida, USA, Proceedings: 1423 - 1428.
49. Wang, P., Chen, X., Xu, F., Lu, D., Cai, W., Ying, K., Wang, Y. ve Hu, Y., Development of Electronic Nose for Diagnosis of Lung Cancer at Early Stage, International Conference on Technology and Applications in Biomedicine, Mayıs 2008, Shenzhen, Proceedings: 588 - 591.
50. Phillips, M., Breath Test for Dedection of Lung Cancer, Patent 5, Aralık 1999, United States, 996, 586.
51. Ping, W., Yi, T., Haibao, X. ve Farong, S., A Novel Method for Diabetes Diagnosis Based on Electronic Nose, Biosens and Bioelectronics, 12, 9-10 (1996) 1031-1036.
52. Vassilis, S., Kodogiannis, J.N., Lygouras, A.T. ve Chowdrey, H.S., 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 (2008) 707-713.

53. Natale, C.D., Mantini, A., Macagnano A., Antuzzi, D., Paolesse, R. ve D'Amico, A., Electronic Nose Analysis of Urine Samples Containing Blood, Physiol. Meas., 20 (1999) 377-384.
54. Lin, Y.L., Guo, H.R., Chang, Y.H., Kao, M.T., Wang, H.H. ve Hong, R.I., Application of The Electronic Nose for Uremia Diagnosis, Sensor and Actuators:B, 76 (2001) 177-180.
55. Di Natale, C., Macagnano, A., Martinelli, E., Paolesse, R., D'arcangelo, G., Roscioni, C., Agro, A. F. ve D'amico A., Lung Cancer Identification by The Analysis of Breath by Means of An Array of Non-Selective Gas Sensors, Biosensors and Bioelectronics, 18 (2002) 1209-1218.
56. Phillips, M., Gleeson, K., Hughes, J.M., Greenberg, J., Catoneo, N.R. ve Baker, L., Volatile Organic Compounds in Breath as Markers of Lung Cancer: A Cross-Sectional Study, The Lancet (British Edition), 353 (1999) 1930-1933.
57. Dutta, R., Gardner, J. W. ve Hines, E. L., ENT Bacteria Classification Using A Neural Network Based Cyranose 320 Electronic Nose, IEEE Sensors, Ekim 2004, Coventry, UK, Proceedings: 324 - 325.
58. Boilot, P., Hines, E. L., Gardner, J. W., Pitt, R., John, S., Mitchell, J. ve Morgan, D. W., Classification of Bacteria Responsible for ENT and Eye Infections Using The Cyranose System, IEEE Sensors Journal, 2, 3 (2002) 247-253.
59. Torsi, L., Tanese, M.C., Cioffi, N., Gallazzi, M.C., Sabbatini, L. ve Zambonin, G.P., Alkoxy-Substituted Polyterthiophene Thin-Film-Transistors as Alcohol Sensor, Sensors and Actuators B, 98 (2004) 204-207.
60. Bruins, M., Rahim, Z., Bos, A., Sande, W.W.J., Endtz, H.P. ve Belkum, A.V., Diagnosis of Active Tuberculosis by E-Nose Analysis of Exhaled Air, Tuberculosis, 93 (2013) 232-238.
61. Fend, R., Bessant, C., Williams, A.J. ve Woodman, A.C, Monitoring Haemodialysis Using Electronic Nose and Chemometrics, Biosens. and Bioelectronics, 19 (2003) 1581-1590.
62. Natale, C.D., Macagnano, A., Paolesse, R., Tarizzo, E., Mantini, A. ve D'Amico, A., Human Skin Odor Analysis by Means of Electronic Nose, Sensors and Actuators B, 65 (2000) 216-219.
63. Natale, C.D., Paolesse, R., D'Arcangelo, G., Comandini, P., Pennazza, G., Martinelli, E., Rullo, S., Roscioni, M.C., Roscioni, C., Finazzi-Agrò, A. ve D'Amico A., Identification of Schizophrenic Patients by Examination of Body Odor Using Gas Chromatography-Mass Spectrometry and A Crossselective Gas Sensor Array, Med Sci Monit., 11, 8 (2005) 366-375 .

64. Ryabtsev, S.V., Shaposhnick, A.V., Lukin, A.N. ve Domashevskaya, E.P., Application of Semiconductor Gas Sensors of Medical Diagnostics, Sensors and Actuators B, 59 (1999) 26-29.
65. Ping, W., Yi, T., Haibao, X. ve Farong, S., A Novel Method for Diabetes Diagnosis Based on Electronic Nose, Biosens and Bioelectronics, 12, 9-10 (1996) 1031-1036.
66. Zhang, Q., Wang, P., Li, J. ve Gao, X., Diagnosis of Diabets by Image Dedection of Breath Using Gas-Sensitive Labs, Biosens and Bioelectronics, 15 (2000) 249-256.
67. Ryabtsev, S.V., Shaposhnick, A.V., Lukin, A.N. ve Domashevskaya, E.P., Application of Semiconductor Gas Sensors of Medical Diagnostics, Sensors and Actuators:B, 59 (1999) 26-29.
68. Fu, W., Huang, Q., Wang, J., Liu, M., Huang, J. ve Chen, B., Detection of Human Papilloma Virus with Piezoelectric Quartz Crystal Genesensors, Sensors and Transducers, 42 (2004) 214-219.
69. Phillips, M., Breath Test for Dedection of Various Diseases, United States Patent 6, April 2001, 221, 026.
70. Mamlouk, A.M., Quantfying Olfactory Perception, Doktora Tezi, University of Lübeck, Institute for Signal Processing, Lübeck, Germany, 2002.
71. Henning, H., 'Der Geruch', Barth, Leipzig, 1916.
72. Woskow, M.H., Multidimensional Scaling of Odors, Doktora Tezi, University of California Los Angeles, Los Angeles, CA, 1964.
73. Schiffman, S.S., Reynolds, M.L. ve Young, F.W., Introduction to Multidimensional Scaling, Academic Press, New York, 1981.
74. <http://www.extension.iastate.edu/publications/pm1963b.pdf> The Science of Smell Part 2: Odor Chemistry. 14 Mayıs 2004.
75. Ruitter, C.C. ve W.J., The Biological Sense of Smell: Olfactory Search Behavior and A Metabolic View for Olfactory Perception, Doktora Tezi, California Institute of Technology, Pasadena, CA, 2000.
76. Dutta, R., Kashwan, K. R., Bhuyan, M., Hines, E.L. ve Gardner, J.W, Electronic Nose Based Tea Quality Standardization, Neural Networks, 16, 5-6 (2003) 847-853.
77. <http://www.dermaneturk.com/okd/sayi322004/dogalkoku.asp>, Doğal Kokunun İçeriği. 29 Kasım 2004.
78. Aktümsek, A., Anatomi ve Fiziyojji İnsan Biyolojisi, 5. Baskı, Nobel Bilim ve Araştırma Merkezi, Ankara, 2010.

79. Franco, M. I., Turin, L., Mershin, A. and Skoulakis, E. M. C., Molecular Vibration-Sensing Component in Drosophila Melanogaster Olfaction, Proceedings of the National Academy of Sciences of the USA, 108, 9 (2011) 3797–3802.
80. Lundstrom, I., Shivaraman, S., Svensson, C. ve Lundkvist, L., A Hydrogen–Sensitive MOS Field–Effect Transistor, Appl. Phys. Lett., 26 (1975) 55-57.
81. James, D., Scott, S. M., Ali, Z. ve Oihare, W. T., Chemical Sensors for Electronic Nose Systems, Microchim. Acta, 49 (2005) 1-17.
82. Sepaniak, M.J., Tromberg, B.J. ve Vodinh, T., Fiber Optic Affinity Sensors in Chemical Analysis, Prog. Anal. Spectrosc., 11 (1988) 481-509.
83. Dickinson, T.A., White, J., Kauer, J.S. ve Walt, D.R., A Chemical-Detecting System Based on A Cross-Reactive Optical Sensor Array, Nature, 382 (1996) 697-700.
84. Barnard, S.M. ve Walt, D.R., A Fibre-Optic Chemical Sensor with Discrete Sensing Sites, Nature, 353 (1991) 338-340.
85. Dickinson, T.A., Michael, K.L., Kauer, J.S. ve Walt, D.R., Convergent, Self-Encoded Bead Sensor Arrays in The Design of An Artificial Nose, Anal. Chem., 71 (1999) 2192-2198.
86. Leipert, D., Rathgeb, F., Herold, M., Mack, J., Gauglitz, G. ve Jung, G., Interaction Between Volatile Organic Compounds and Cyclopeptides Detected with Reflectometric Interference Spectroscopy, Anal Chim Acta, 392 (1999) 213-221.
87. Martinelli, G. ve Carotta, M.C., Thick-Film Gas Sensors, Sens. and Actuat B, 23 (1995) 157-161.
88. Tekbıyık, P., Nefes Kokusundan Diabet Tanısı İçin QCM Tabanlı Sistem Tasarımı, Yüksek Lisans Tezi, Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya, 2007.
89. Wenzel, S.W. ve White, R.M, A Multisensor Employing An Ultrasonic Lamb-Wave Oscillator, IEEE Trans. Electron Devices, 35 (1988) 735-743.
90. Grassi, A.M., Lombardi, V., Ferragina, P.M., Capone, L.S., Francioso, P.S. ve Baschiroto, A., Gas Sensor Interface Circuit Based on Calibration Free Novel Frequency Measurement Approach with 16-Bit Digital Output, IEEE Sensors, Ekim 2006, Daeegu, Korea, Proceedings: 220-223.
91. Marco, S., Signal Preprocessing: Digital Filtering, Spectral Analysis and Basic Features, 3rd NOSE Short Course Fundamentals of Signal and Data Processing, [http://205.209.45.207/Hantale/WEB.nsf/Anexos/DC078EBF1AF054A887257378007A61C7/\\$FILE/Signal_Preprocessing_def.pdf](http://205.209.45.207/Hantale/WEB.nsf/Anexos/DC078EBF1AF054A887257378007A61C7/$FILE/Signal_Preprocessing_def.pdf) 07.11.2010.

92. Gutierrez-Osuna, R. ve Nagle, H.T., A Method for Evaluating Data-Preprocessing Techniques for Odor Classification with An Array of Gas Sensors, IEEE Transactions on Systems, Man, and, Cybernetics-Part B, 29, 5 (1999) 626-632.
93. R.F.C. Rodriguez, A Low Cost Electronic Nose for Multimedia Applications, Yüksek Lisans Tezi, University of Alberta, Faculty of Graduate Studies and Research, Edmonton, Alberta, 2005.
94. Pardo, M., Niederjaufner, G., Benussi, G., Comini, E., Faglia, G., Sberveglieri, G., Holmberg, M. ve Lundstrom, I., Data Preprocessing Enhances The Classification of Different Rands of Espresso Coffee with An Electronic Nose, Sensors and Actuators B, 69 (2000) 397-403.
95. Sundic, T., Marco, S., Samitier, J. ve Wide, P., Electronic Tongue and Electronic Nose Data Fusion İn Classification with Neural Networks and Fuzzy Logic Based Models, Instrumentation and Measurement Technology Conference, IEEE Sensors, Mayıs 2000, Baltimore, MD, Proceedings: 1474 – 1479.
96. Distanto, C., Leo, M., Siciliano, P. ve Persaud, K.C., The Study of Feature Extraction Methods for An Electronic Nose, Sensors and Actuators B, 87 (2002) 274-288.
97. Carmel, L., Levy, S., Lancet, D. ve Harel, D., A Feature Extraction Method for Chemical Sensors in Electronic Noses, Sensors and Actuators B, 93 (2003) 67-76.
98. Hai, Z. ve Wang, J., Electronic Nose and Data Analysis for Detection of Maize Oil Adulteration İn Sesame Oil, Sensors and Actuators B, 119 (2006) 449-455.
99. Yin, Y., Yu, H. ve Zhang, H., Feature Extraction Method Based on Wavelet Packet Analysis for Discrimination of Chinese Vinegars Using A Gas Sensors Array, Sensors and Actuators B, 134 (2008) 1005-1009.
100. Yu, S., Lin, T. ve Ou, J., Recognition Feature Extraction of Pernicious Gases İn Piggery Based on Wavelet Transformand Genetic Algorithm, Information Engineering and Computer Science, Aralık 2009, Wuhan, Proceedings: 1 – 4.
101. Distanto, C. ve Siciliano, P., A Comparison Between Feature Extraction Methods of An Electronic Nose Response, Electronics, Circuits and Systems, Eylül 2001, Italy, Proceedings: 1243 - 1246.
102. Brudzewski, K. ve Ulaczyk, J., An Effective Method for Analysis of Dynamic Electronic Nose Responses, Sensors and Actuators B, 140 (2009) 43-50.
103. Green, G.C., Chan A.D.C., Dan, H. ve Lin, M., Using A Metal Oxide Sensor (MOS)-Based Electronic Nose for Discrimination of Bacteria Based on İndividual Colonies İn Suspension, Sensors and Actuators B, 152 (2011) 21-28.
104. Zhang, S., Xie, C., Hu, M., Li, H., Bai, Z. ve Zeng, D., An Entire Feature Extraction Method of Metal Oxide Gas Sensors, Sensors and Actuators B, 132 (2008) 81-89.

105. Zhang, S., Xie, C., Zeng, D., Li, H., Bai, Z. ve Cai, S., A Method of Feature Extraction From The Desorption Part of MOX's Response Curves To Gases, IEEE Sensors Journal, 8, 11 (2008) 1816-1823.
106. Zhang, S., Xia, X., Xie, C., Cai, S., Li, H. ve Zeng, D., A Method of Feature Extraction on Recovery Curves for Fast Recognition Application Application with Metal Oxide Gas Sensor Array, IEEE Sensors Journal, 9, 12 (2009) 1705-1710.
107. Leone, A., Distanto, C., Ancona, N., Persaud, K. C., Stella, E. ve Siciliano, P., A Powerful Method for Feature Extraction and Compression of Electronic Nose Responses, Sensors and Actuators B, 105 (2005) 378-392.
108. Osuna, R.G., Pattern Analysis for Machine Olfaction: A Review, IEEE Sensors Journal, 2, 3 (2002) 189-202.
109. Gutierrez-Osuna, R., Introduction To Pattern Analysis, Texas A&M University, LECTURE 10: Linear Discriminant Analysis, <http://www.docstoc.com/docs/22740267/LECTURE-10-Linear-Discriminant-Analysis-Linear-Discriminant-Analysis> 10.01.2011.
110. Phaisangittisagul, E., Nagle, H. T. ve Areekul, V., Intelligent Method for Sensor Subset Selection for Machine Olfaction, Sensors and Actuators B: Chemical, 145 (2010) 507-515.
111. NABIYEV, V., Yapay Zeka (Problemler, Yöntemler, Algoritmalar), İkinci Baskı, Seçkin Yayıncılık, Trabzon, 2005.
112. Günel, S., Örüntü Tanıma Uygulamalarında Altuzay Analiziyle Öznitelik Seçimi ve Sınıflandırma, Doktora Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2008.
113. Williams, A.L., Prediction of Odor Pleasantness Using Electronic Nose Technology and Artificial Neural Networks, Doktora Tezi, The Pennsylvania State University, The Graduate School College of Engineering, Pennsylvania, 2006.
114. Türkoğlu, İ., Örüntü Tanıma Sistemleri (Ders Notları), Fırat Üniversitesi, <http://perweb.firat.edu.tr/default.asp?content=personelgoster.asp&uid=E-A-0084> 02.07.2010.
115. Bishop, C., Neural Networks for Pattern Recognition, Second Edition, Oxford University Press, Oxford, 1995.
116. Keller, P.E., Mimicking Biology: Applications of Cognitive Systems to Electronic Noses, IEEE, International Symposium on Intelligent Control/Intelligent System One Semiotics, Eylül 1999, Cambridge, MA, Proceedings: 447-451.
117. Gardner, J.W. ve Yinon, J., Electronic Noses & Sensors for The Detection of Explosives, Kluwer Academic Publishers, New York, 2004.

118. Dutta, R. ve Dutta, R., Intelligent Bayes Classifier (IBC) for ENT Infection Classification in Hospital Environment, BioMedical Engineering, 5, 1 (2006) 65.
119. Belhourai, S.M. ve Bermak, A., Gas Identification Using Density Models, Pattern Recognition Letters, 26, 6 (2005) 699-706.
120. Pearce, T.C., Computational Parallels Between the Biological Olfactory Pathway and Its Analogue 'The Electronic Nose': Part II. Sensor-based machine olfaction, Biosystems Journal, 41, 2 (1997) 69 - 90.
121. Ye, J, Janardan, R. ve Li, Q., Two Dimensional Linear Discriminant Analysis, Neural Information Processing Systems, Aralık 2005, Vancouver and Whistler, B.C., Proceedings: 1-8.
122. Teknomo, K., Linear Discriminant Analysis-Tutorial, <http://people.revoledu.com/kardi/tutorial/LDA/LDA.html> 12.03.2009.
123. Özkan, Y., Veri Madenciliği Yöntemleri, Papatya Yayıncılık Eğitim, İstanbul, 2008.
124. Pardo, M. ve Sberveglieri, G., Classification of Electronic Nose Data with Support Vector Machines, Sensors and Actuators B: Chemical, 107, 2 (2005) 730–737.
125. Chen, Q., Zhao, J., Chen, Z., Lin, H. ve Zhao, D., Discrimination of Green Tea Quality Using The Electronic Nose Technique and The Human Panel Test, Comparison of Linear And Nonlinear Classification Tools, Sensors and Actuators B: Chemical, 159, 1 (2011) 294–300.
126. Barbri, N.E., Llobet, E., Baric, N.E., Correig, X. ve Bouchikhia, B., Application of A Portable Electronic Nose System to Assess The Freshness of Moroccan Sardines, Materials Science and Engineering: C, 28, 5–6 (2008) 666–670.
127. Güney, S. ve Atasoy, A., Multiclass Classification of n-Butanol Concentrations with K-Nearest Neighbor Algorithm And Support Vector Machine in An Electronic Nose, Sensors and Actuators B: Chemical, 166–167 (2012) 721–725.
128. Muezzinoglu, M.K., Vergara, A., Huerta, R., ve Rabinovich, M.I., A Sensor Conditioning Principle for Odor Identification, Sensors and Actuators B: Chemical, 146, 2 (2010) 472–476.
129. Kuskea, M., Rubio, R., Romain, A.C., Nicolas, J. ve Marco, S., Fuzzy k-NN Applied to Moulds Detection, Sensors and Actuators B: Chemical, 106, 1 (2005) 52–60.
130. Edin, B., Qcm-Ssc Sensör Dizisiyle Algılanan Sevoflurane Anestezik Gaz Seviyelerinin Yapay Sinir Ağları Kullanarak Belirlenmesi, Yüksek Lisans Tezi, Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya, 2007.

131. Çakmak, N., Qcm-Ssc Gaz Sensör Dizisi Kullanarak İnsan Nefesinden Diyabet Tanısı, Yüksek Lisans Tezi, Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya, 2007.
132. Sitar, A.M., The Environmental Electronic Nose, Yüksek Lisans Tezi, Concordia University, Department of Physics, Montreal, Quebec, 1995.
133. www.figarosensor.com/, Operation Principle of Figaro Gas Sensors. 13.08.2008.
134. www.ti.com/lscds/ti/analog/sensors/overview.pagehttp://sine.ni.com/nips/cds/view/p/1ang/en/nid/14128, Sensor Products. 17.08.2008.
135. Li, T., The application of Artificial Neural Networks in the Electronic Nose for Odour Measurement, Yüksek Lisans Tezi, University of Manitoba, Department of Biosystems Engineering, Winnipeg, Manitoba, 2004.
136. www.alpha-mos.com/analytical-instruments.php, Sensory Analysis of Odor, Taste, and Vision with Analytical Instruments. 13.02.2009.
137. Amore, J.E., Johnston, J.W. ve Rubin, M., The Stereochemical Theory of Odor, Sci. American, 210, 2 (1964) 42-49.
138. Barbri, N.E., Amari, A., Vinaixa, M., Bouchikhi, B., Correig, X. ve Llobet, E., Building of a Metal Oxide Gas Sensor-Based Electronic Nose to Assess the Freshness of Sardines Under Cold Storage, Sensors and Actuators B, 128 (2007) 235-244.
139. Limbo, S., Sinelli, N., Torri, L. ve Riva, M., Freshness Decay and Shelf Life Predictive Modeling of European Sea Bass (*Dicentrarchus Labrax*) Applying Chemical Methods And Electronic Nose, Food Science and Technology, 42 (2009) 977-984.
140. Rodriguez-Mendez, M.L, Gay, M., Apetrei, C.J. ve De Saja, A., Biogenic Amines and Fish Freshness Assessment Using A Multisensory System Based on Voltammetric Electrodes. Comparison Between CPE And Screen-Printed Electrodes, Electrochimica Acta, 54 (2009) 7033-7041.
141. Guohua, H., Lyve, W., Yanhong, M. ve Lingxia, Z., Study of Grass Carp (*Chenopharyngood Idellus*) Quality Predictive Model Based on Electronic Nose, Sensors and Actuators B: Chemical, 166-167 (2012) 301-308.
142. Perera, A., Pardo, A., Barrettino, D., Hierlermann, A. ve Marco, S., Evaluation of Fish Spoilage by Means of A Single Metal Oxide Sensor Under Temperature, Sensors and Actuators B: Chemical, 146 (2010) 477-482.
143. Brudzewski, K. ve Osowski, S., Recognition of Cofee Using Differential Electronic Nose, IEEE Transactions on Instrumentation and Measurement, 61, 6 (2012) 1803-1810.

144. Hines, E.L., Llobet, E. ve Gardner, J.W., Electronic Noses: A Review of Signal Processing techniques, IEE Proc.- Circuits Devices Syst., 146, 6 (1999) 297-310.
145. Osuna, R. G., Nagle, H. T. ve Schiffman, S. S., Transient Response Analysis of an Electronic Nose Using Multi-Exponential Models, Sensors and Actuators B:Chemical, 61 (1999) 170-182.
146. Aksebzeci, B.H., Mikroorganizmaların Elektronik Burun Teknolojisi Kullanılarak Tanımlanması ve Sınıflandırılması, Doktora Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, 2011.
147. Jain, A.K., Duin, R.P.W. ve Mao, J., Statistical Pattern Recognition : A Review, IEEE Transactionson Pattern Analysis and Machine Intelligence, 22, 1 (2000) 4-37.
148. Asyali, M. ., Colak, D., Demirkaya, O. ve Inan, M. ., Gene Expression Profile Classification: A Review, Current Bioinformatics, 1 (2006) 55-73.
149. Theodoridis, S. ve Koutroumbas, K., Pattern Recognition, Third Edition, Elsevier, USA, 2006.
150. Balakrishnama, S. and Ganapathiraju, A., Linear Discriminant Analysis-a Brief Tutorial, Institute for Signal and information Processing, Mississippi State University, Department of Electrical and Computer Engineering, Mississippi,1998.
151. Fukunaga, K., Introduction to Statistical Pattern Recognition, Academic Press, San Diego, California, 1990.
152. Chen, P.H., Lin, C.J. ve Schölkopf, B., A Tutorial on v-Support Vector Machines, Appl. Stoch. Models. Bus. Ind., 21 (2005) 111-136.
153. Özmen, N.G., Beyin Bilgisayar Arayüzü Tasarımı için Farklı Zihinsel Aktiviteler Esnasında Oluşan EEG İşaretlerinin Analiz Edilmesi ve Sınıflandırılması, Doktora Tezi, KTÜ, Fen Bilimleri Enstitüsü, Trabzon, 2010.
154. Hastie, T. ve Tibshirani, R., Classification of Pairwise Coupling, Annals of Statistic, 26 (1998) 451-471.
155. Mathur, A. ve Foody, G.M., Multiclass and Binary SVM classification: Implications for Training and Classification Users, IEEE Geoscience and Remote Sensing Letters, 5 (2008) 241-245.
156. Hsu, C.W. ve Lin, C.J., A Comparison of Methods for Multiclass Support Vector Machines, IEEE Transactions on Neural Networks, 13 (2002) 415-425.
157. Duan, K.B. ve Keerthi, S.S., Which is the Best Multiclass SVM method? An Empirical Study, International Workshop on Multiple Classifier Systems, Haziran 2005, Seaside, CA, USA, Proceedings: 278-285.

158. Shaffer, R.E., Pehrsson, S.L.R. ve McGill, R. A., A Comparison Study of Chemical Sensor Array Pattern Recognition Algorithms, Analytica Chimica Acta, 384 (1999) 305-317.
159. Ögüdücü, Ş.G., Veri Madenciliği Farklı Sınıflandırma Yöntemleri: Ders Notları, <http://www.ninova.itu.edu.tr/EgitimDetay.aspx?eId=195/> 14.06.2009.
160. Gila, L., Barat, J.M., Breijo, E.G., Ibañez, J., Máñez, R.M., Soto, J., Llobet, E., Brezmes, J., Aristoy, M.C. ve Toldrá, F., Fish Freshness Analysis Using Metallic Potentiometric Electrodes, Sensors and Actuators B: Chemical, 131 (2008) 362-370.
161. Barbri, N.E., Mirhisse, J., Ionescu, R., Bari, N.E., Correig, X., Bouchikhi, B. ve Llobet, E., An Electronic Nose System Based on A Micro-Machined Gas Sensor Array to Assess the Freshness of Sardines, Sensors and Actuators B: Chemical, 141 (2009) 538-543.
162. Haugen, J.E., Chanie, E., Westad, F., Jonsdottir, R., Bazzo, S., Labreche, S., Marcq, P., Lundby, F. ve Olafsdottir, G., Rapid Control of Smoked Atlantic Salmon (*Salmo Salar*) Quality by Electronic Nose: Correlation with Classical Evaluation Methods, Sensors and Actuators B: Chemical, 116 (2006) 72-77.
163. Natale, C.D., Olafsdottir, G., Einarsson, S., Martinelli, E., Paolesse, R. ve D'Amico, A., Comparison and Integration of Different Electronic Noses for Freshness Evaluation of Cod Fish Fillets, Sensors and Actuators B: Chemical, 77 (2001) 572-578.

ÖZGEÇMİŞ

Selda GÜNEY; 1982 yılında Erzurum’da doğdu. İlk ve orta öğrenimini Samsun’un Çarşamba ilçesinde tamamladı. 1999 yılında Manisa’nın Salihli ilçesinde bulunan Sekine Evren Anadolu Lise’sinden mezun oldu. 1999 yılında, ÖSS ile yerleştirildiği Karadeniz Teknik Üniversitesi, Elektrik-elektronik Mühendisliği Bölümü’nü 2004 yılında bitirdi. 2007 yılında aynı bölümde yüksek lisansını tamamladı. 2007 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda doktora çalışmalarına başladı. 2004-2005 yıllarında DEKA Dijital firmasında Araştırma Geliştirme Mühendisi olarak çalıştı. 2005 yılında Araştırma Görevlisi olarak atandığı KTÜ Elektrik-Elektronik Mühendisliği Bölümünde halen çalışmaya devam etmektedir. Doktora çalışması esnasında, KTÜ BAP destekli 2009.112.004.3 numaralı projede araştırmacı statüsünde görev aldı. 2012 yılında ERASMUS Staj Programı çerçevesinde ve Institute for Bioengineering of Catalonia (IBEC) kurumunun burs desteğiyle, Barcelona Üniversitesi işbirliğinde ‘Farklı elektronik burun cihazları için kalibrasyon transferi’ konusunda İspanya’nın Barselona şehrinde çalışma yaptı. Yabancı dil olarak İngilizce bilmektedir. Doktora tezi kapsamında yaptığı başlıca yayınlar aşağıda verilmektedir.

SCI İndeksli Dergiler:

1. Güney, S. ve Atasoy, A., Multiclass Classification of n-Butanol Concentrations with k-Nearest Neighbor Algorithm and Support Vector Machine in an Electronic Nose, Sensors and Actuators B: Chemical, 166-167 (2012) 721-725.
2. Güney, S., Atasoy, A. ve Burget, R., Electronic Nose Odor Classification with Advanced Decision Tree Structures, Radioengineering, 2013 kabul edildi.

Uluslararası Konferanslar:

1. Güney, S. ve Atasoy, A., Classification of n-Butanol Concentrations with k-NN Algorithm and ANN in Electronic Nose, INISTA International Symposium on INnovations in Intelligent SysTems and Applications, Haziran, 2011, İstanbul, Türkiye, Bildiriler Kitabı: 15–18.
2. Güney, S. ve Atasoy, A., An Electronic Nose System for Assessing Horse Mackerel Freshness, Innovations in Intelligent Systems and Applications (INISTA), Temmuz 2012, Trabzon, Türkiye, Bildiriler Kitabı.
3. Güney, S. ve Atasoy, A., Fish Freshness Assessment by Using Electronic Nose, 2013 36th International Conference on Telecommunications and Signal Processing (TSP), Temmuz 2013, Roma, İtalya, Bildiriler Kitabı.