

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**ELEKTRONİK BURUN İLE FARKLI KALİTEDEKİ DOĞU KARADENİZ  
ÇAYLARININ SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ**

**Elektrik-Elektronik Müh. Yavuz KABLAN**

**OCAK 2018  
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**ELEKTRONİK BURUN İLE FARKLI KALİTEDEKİ DOĞU KARADENİZ**  
**ÇAYLARININ SINIFLANDIRILMASI**

**Elektrik-Elektronik Müh. Yavuz KABLAN**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde**  
**"ELEKTRİK-ELEKTRONİK YÜKSEK MÜHENDİSİ"**  
**Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 02.01.2018**  
**Tezin Savunma Tarihi : 26.01.2018**

**Tez Danışmanı: Doç. Dr. Ayten ATASOY**

**Trabzon 2018**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü**  
**Elektrik-Elektronik Mühendisliği Anabilim Dalında**  
**Yavuz KABLAN tarafından hazırlanan**

**ELEKTRONİK BURUN İLE FARKLI KALİTEDEKİ DOĞU KARADENİZ**  
**ÇAYLARININ SINIFLANDIRILMASI**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun ..../201.. gün ve 1555 sayılı kararıyla oluşturulan jüri tarafından yapılan sınavda**

**YÜKSEK LİSANS TEZİ**  
**olarak kabul edilmiştir.**

**Jüri Üyeleri**

**Başkan** : .....

**Üye** : .....

**Üye** : .....

**Prof. Dr. Sadettin KORKMAZ**  
**Enstitü Müdürü**

## ÖNSÖZ

Elektronik burun ile kokuların ayırt edilmesi sayesinde pek çok önemli başarı sağlanmıştır. Tıptan askeri savunma sistemlerine, akıllı ev sistemlerinden otomotiv endüstrisine kadar pek çok alanda elektronik burun teknolojisinden faydalanılmaktadır. Bu alanlardan en önemlisi ise canlıları yakından ilgilendiren gıda sektörüdür. Bu tez çalışması ile alınan gıdada yaşam ve kalite standartlarının yükseltilmesi hedeflenmiştir.

Çalışmalarında danışmanlığımı üstlenen değerli hocam Doç. Dr. Ayten ATASOY'a ilgisi, desteği ve tecrübesiyle çalışmaların yürütülmesinde yardımlarını esirgemediği için teşekkürü bir borç bilirim.

Bu tez kapsamında yapılan çalışmaların her birinin gerçekleştirilebilmesi için kullanılan elektronik burun deney düzeneğine 2009.112.004.3 proje numarasıyla destek veren Karadeniz Teknik Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne ve bu projede araştırmacı olarak çalışmış olan Yrd. Doç. Dr. Selda GÜNEY'e desteklerinden dolayı teşekkür ederim.

Seçmiş olduğum tez çalışmasında her zaman yanımda olan ve değerli zamanını benimle birlikte değerlendiren değerli arkadaşım Arş. Gör. Ümit ÖZSANDIKCIOĞLU'na da ayrıca teşekkür ederim.

Bu tez çalışması boyunca, beni her koşulda koşulsuzca destekleyen, yardımlarını esirgemeyen, anlayış gösteren, sevgileriyle yanımda olan aileme ve dostlarıma çok teşekkür ederim.

Yavuz KABLAN

Trabzon 2018

## **TEZ ETİK BEYANNAMESİ**

Yüksek Lisans Tezi olarak sunduđum “Elektronik Burun ile Farklı Kalitedeki Dođu Karadeniz aylarının Sınıflandırılması” başlıklı bu alıřmayı bařtan sona kadar danıřmanım 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. 26/01/2018

Yavuz KABLAN

# İÇİNDEKİLER

	<b><u>Sayfa No</u></b>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VII
SUMMARY .....	VIII
ŞEKİLLER DİZİNİ .....	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER DİZİNİ .....	XII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Koku Uzayı .....	3
1.3. Biyolojik Koku Algılama Sistemi.....	4
1.4. Elektronik Burun.....	6
1.4.1. Algılayıcı Birim.....	8
1.4.1.1. Sensörler.....	10
1.4.1.1.1. Elektrokimyasal Sensörler.....	10
1.4.1.1.2. Isıl Sensörler.....	12
1.4.1.1.3. Optik Sensörler.....	13
1.4.1.1.4. Gravimetrik Sensörler .....	14
1.4.2. Dönüştürücü Birim .....	14
1.4.3. Elektronik Birim .....	15
1.4.4. İşaret Koşullama Birimi .....	16
1.4.5. İşaret Ön İşleme Birimi .....	17
1.4.5.1. Referans Düzeltme .....	17
1.4.5.2. Boyut İndirgeme .....	19
1.4.5.2.1. Öznitelik Çıkarma. ....	19
1.4.5.2.2. Öznitelik Alt Kümesi Seçimi.....	21
1.4.5.2.3. Temel Bileşen Analizi .....	21
1.4.5.3. Normalizasyon.....	23
1.4.6. Örüntü Tanıma Birimi .....	24

1.4.6.1.	Destek Vektör Makineleri .....	25
1.4.6.2.	Doğrusal Ayırma Analizi .....	29
1.4.6.3.	k-En Yakın Komşu .....	32
1.4.6.4.	Karar Ağaçları .....	34
1.4.6.5.	Sınıflandırıcı Toplulukları Yöntemi.....	35
1.5.	K-Katlı Çapraz Doğrulama ve Başarı Ölçümü.....	39
2.	YAPILAN ÇALIŞMALAR.....	41
2.1.	Elektronik Burun Deney Düzeneği .....	41
2.1.1.	Kullanılan Ekipmanlar .....	41
2.1.2.	Elektronik Burun Deney Düzeneğinin Çalışma Sistemi.....	45
2.2.	Yapılan Çalışmalar.....	46
2.2.1	UOB Ölçümlerinin Yapılması .....	46
2.2.2	Referans Gazın Çıkartılması .....	50
2.2.3.	Referans Düzeltmesi .....	54
2.2.4.	İletkenlik Dönüşümü.....	57
2.2.5.	Öznitelik Çıkarma.....	61
3.	BULGULAR.....	63
4.	SONUÇLAR VE ÖNERİLER .....	76
5.	KAYNAKLAR.....	78
ÖZGEÇMİŞ		

Yüksek Lisans Tezi

ÖZET

ELEKTRONİK BURUN İLE FARKLI KALİTEDEKİ DOĞU KARADENİZ  
ÇAYLARININ SINIFLANDIRILMASI

Yavuz KABLAN

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı  
Danışman: Doç. Dr. Ayten ATASOY  
2018, 83 Sayfa

Bu tez kapsamında, elektronik burunun nesnelere ait kokuların algılanmasından faydalanılarak, Doğu Karadeniz'e özgü yetişen çay bitkisinden elde edilen çay içeceklerinin çeşitleri arasındaki ayırımı için çalışmalar yapılmıştır. Tezde altı adet farklı çay türüne ait bilgiden oluşan bir veri tabanı oluşturulmuştur. Bu veri tabanında OFÇAY markasına ait; Çamlıca Filizi, Hazine, Everyday, Regular ile DEREN markasına ait Tomurcuk Bergamot çayı ve ÇAYKUR'a ait Tomurcuk çayı kullanılmıştır. Veri tabanı, demlenmiş çayların ortama yaydığı kokulardan faydalanılarak oluşturulmuştur. Yapılan işlemlerde taşıyıcı gaz olarak ortam havası kullanılmış, işlemlerde ortam havasının olumsuz etkilerinden kaçınmak için koku bilgisi ile ortam havasına ait bilgi birbirinden çıkarılmıştır. Birbirinden ayırt edilmeye çalışılan nesnelere birbirlerine çok yakın türler oldukları için ortama yaydıkları kokunun birbirlerinden ayırt edilebilmesi için öznitelikler ve sınıflandırma algoritmaları araştırılmıştır. Bu araştırmalar sonucunda türev ve integrale bağlı özniteliklerin daha fazla başarı sağladığı görülmüştür. Bununla birlikte öznitelikler üzerinde normalizasyonun da etkisi olup olmadığı incelenmiştir. Bu bağlamda normalizasyonun sınıflandırmaya olumlu etkisi olduğu sonucuna varılmıştır. Verileri sınıflandırmak için; Karar ağaçları, k-En yakın komşu, Doğrusal ayırım analizi, Destek vektör makineleri ve Sınıflandırıcı toplulukları algoritmaları kullanılmıştır. En başarılı sonuç Doğrusal ayırım analizi algoritması kullanılarak elde edilmiştir.

**Anahtar Kelimeler:** Elektronik burun, karar ağaçları, k-en yakın komşu, destek vektör makineleri, doğrusal ayırım analizi, çay, normalizasyon



Master Thesis

SUMMARY

CLASSIFICATION OF THE EAST BLACK SEA TEAS IN DIFFERENT  
QUALITIES BY ELECTRONIC NOSE

Yavuz KABLAN

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Electric-Electronic Engineering Graduate Program  
Supervisor: Assoc. Prof. Dr. Ayten ATASOY  
2018, 83 Pages

In the scope of this academic work, studies were carried out to determine the distinction between the varieties of tea drinks obtained from tea plants grown in the Eastern Black Sea, by using the electronic nose which perceives odours. A database consisting of the data of 6 different tea species is used in the thesis. Çamlıca Filizi, Hazine, Everyday, and Regular from OFÇAY brand; Tomurcuk Bergamot tea from DEREN brand; and Tomurcuk from ÇAYKUR brand were used in this database. The database was created by using the smell of the brewed tea. Ambient air was used in the processes as the carrier gas type. Moreover, the data of the ambient air and the data of the smell were separated in order to avoid the adverse effects of the ambient air in the processes. Because the object to be distinguished from each other by using the electronic nose are very similar to each other, the attributes and classification algorithms have been studied so that they can be distinguished from each other. As a result of these studies, it has been observed that the attributes related to the derivatives and integrals are more successful. It has also been examined whether there is an effect of normalization on the attributes. In this context, the result is that the normalization has a positive effect on the classification. Decision trees, k-Nearest neighbours, Linear Segmentation Analysis, Support Vector Machines and Classifier ensemble method algorithms are used in order to classify the data. The most successful result was obtained by using linear discriminant analysis.

**Key Words:** Electronic nose, decision trees, k-nearest neighbors, support vector machines, linear discrimination analysis, tea, normalization

## ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Henning Piramidi .....	4
Şekil 2. İnsanda bulunan biyolojik koku algılama sistemi .....	5
Şekil 3. Standart yapıdaki bir elektronik burunun çalışma sistemi .....	7
Şekil 4. MOS Sensörün İç Yapısı.....	12
Şekil 5. MOS gerilim bölücü arayüz devresi.....	15
Şekil 6. Bergamot Çayı'na ait kokunun ham sensör verileri.....	18
Şekil 7. Bergamot Çayı'na ait sensör verilerinin referans düzeltme işlemi.....	19
Şekil 8. Optimum hiper-düzlem ve destek vektörleri.....	27
Şekil 9. Doğrusal olarak ayırlamayan veriler ve hiper-düzlem.....	28
Şekil 10. Kernel fonksiyonu ile oluşan girdi ve özellik uzayı.....	29
Şekil 11. 3-boyutlu verilerin alt uzaylardaki yansımaları.....	30
Şekil 12. k-En yakın komşu algoritması k seçimi .....	33
Şekil 13. Karar ağacı yapısı.....	35
Şekil 14. UOB iletim sistemi elemanları a) Hava Pompası, b) Selenoid vana ve teflon boru.....	42
Şekil 15. Deneylede kullanılan örneğe ait koku haznesi.....	42
Şekil 16. Elektronik burun deney düzeneğinde kullanılan sensör haznesi.....	43
Şekil 17. a) Sensör arayüz devresi, b) kontrol arayüz devresi.....	44
Şekil 18. Elektronik burun deney düzeneği blok şeması.....	45
Şekil 19. Yapılan çalışmalara ait blok şeması .....	46
Şekil 20. Referans olarak alınan ortam havasına ait sensör ölçümleri .....	47
Şekil 21. Bergamot çayına ait sensör ölçümleri .....	47
Şekil 22. Çamlıca çayına ait sensör ölçümleri.....	48
Şekil 23. Everyday çayına ait sensör ölçümleri.....	48
Şekil 24. Hazine çayına ait sensör ölçümleri.....	49
Şekil 25. Regular çayına ait sensör ölçümleri .....	49
Şekil 26. Tomurcuk çayına ait sensör ölçümleri .....	50
Şekil 27. Referans gazı çıkartılmış Bergamot çayına ait sensör ölçümleri .....	51
Şekil 28. Referans gazı çıkartılmış Çamlıca çayına ait sensör ölçümleri .....	51
Şekil 29. Referans gazı çıkartılmış Everyday çayına ait sensör ölçümleri .....	52
Şekil 30. Referans gazı çıkartılmış Hazine çayına ait sensör ölçümleri .....	52

Şekil 31. Referans gazı çıkartılmış Regular çayına ait sensör ölçümleri .....	53
Şekil 32. Referans gazı çıkartılmış Tomurcuk çayına ait sensör ölçümleri .....	53
Şekil 33. Referans düzeltmesi yapılmış Bergamot çayına ait sensör ölçümleri.....	54
Şekil 34. Referans düzeltmesi yapılmış Çamlıca çayına ait sensör ölçümleri .....	55
Şekil 35. Referans düzeltmesi yapılmış Everyday çayına ait sensör ölçümleri .....	55
Şekil 36. Referans düzeltmesi yapılmış Hazine çayına ait sensör ölçümleri .....	56
Şekil 37. Referans düzeltmesi yapılmış Regular çayına ait sensör ölçümleri.....	56
Şekil 38. Referans düzeltmesi yapılmış Tomurcuk çayına ait sensör ölçümleri.....	57
Şekil 39. İletkenlik dönüşümü yapılmış Bergamot çayına ait sensör ölçümleri .....	58
Şekil 40. İletkenlik dönüşümü yapılmış Çamlıca çayına ait sensör ölçümleri .....	58
Şekil 41. İletkenlik dönüşümü yapılmış Everyday çayına ait sensör ölçümleri.....	59
Şekil 42. İletkenlik dönüşümü yapılmış Hazine çayına ait sensör ölçümleri.....	59
Şekil 43. Referans düzeltmesi yapılmış Regula çayına ait sensör ölçümleri.....	60
Şekil 44. İletkenlik dönüşümü yapılmış Tomurcuk çayına ait sensör ölçümleri.....	60
Şekil 45. Normalizasyonun sınıflandırma başarısına etkisi.....	74

## TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Elektronik burun uygulamalarında kullanılan sensörlere ait özellikler .....	8
Tablo 2. Gaz sensörleri, direnç değerleri ve tepki verdiği gazlar .....	44
Tablo 3. Normalize edilmemiş verinin karar ağaçları ile sınıflandırılmasına ilişkin sınıflandırma başarıları .....	63
Tablo 4. Normalize edilmiş verinin karar ağaçları ile sınıflandırılmasına ilişkin sınıflandırma başarıları .....	64
Tablo 5. Normalize edilmiş ve normalize edilmemiş verinin doğrusal ayırım analizi ile sınıflandırılmasına ilişkin sınıflandırma başarıları .....	65
Tablo 6. Normalize edilmemiş verinin destek vektör makineleri ile sınıflandırılmasına ilişkin sınıflandırma başarıları .....	66
Tablo 7. Normalize edilmiş verinin destek vektör makineleri ile sınıflandırılmasına ilişkin sınıflandırma başarıları .....	67
Tablo 8. Normalize edilmemiş verinin k-en yakın komşu ile sınıflandırılmasına ilişkin sınıflandırma başarıları .....	68
Tablo 9. Normalize edilmiş verinin k-en yakın komşu ile sınıflandırılmasına ilişkin sınıflandırma başarıları .....	69
Tablo 10. Normalize edilmiş verinin k-en yakın komşu algoritması kullanılarak en yakın 7 komşusun sınıflandırma başarıları .....	70
Tablo 11. Alt örnekleme yöntemiyle boyutu azaltılan verinin sınıflandırılmasına ilişkin sınıflandırma başarıları .....	72
Tablo 12. Sensör optimizasyonu yapılmış ve yapılmamış bazı çayların sınıflandırma başarıları .....	73
Tablo 13. En yüksek sınıflandırma başarıları ve işlem süreleri .....	74

## SEMBOLLER DİZİNİ

MOS	Metal Oxide Semiconductor
MOSFET	Metal Oxide Semiconductor Field Effect Transistor
QCM	Quartz Crystal Microbalance
SAW	Surface Acoustic Wave
CO	Karbonmonoksit
CP	Conducting Polymer
SPR	Surface Plasmon Resonance
CMOS	Complementary Metal Oxide Semiconductor
$I$	Kokular arasındaki ölçüm bilgisinin birbirine yakınlığı
$V_{d,k,s}$	Referans düzeltmesi uygulanmış işaretin gerilim değeri
$V_{k,s}(t_k)$	Sensörlerden $t$ anında ölçülen gerilim değerini
$V_{k,s}(t_1)$	Sensörlerden ilk anda ölçülen gerilim değeri
$x_{ij}$	Matristeki her bir eleman
$r_{ij}$	Normalize edilmiş matristeki her bir eleman
$w$	Ağırlık vektörü
$k$	Eğilim değeri
$a$	N-boyutlu veri uzayı
$b$	Sınıf etiketleri
$s_j$	Standart sapma
$\xi_j$	Pozitif yapay değişken
$\beta$	Lineer model katsayısı
$C$	Kovaryans matrisi
$\mu_1, \mu_2$	Ortalama vektörler
$k$	En yakın komşu sayısı
$B$	Veriye ait öznitelikler
$T$	Sınıf değeri
$SD$	Sınıflandırma başarısı

<i>OSD</i>	Ortalama sınıflandırma başarısı
<i>DVSV</i>	Dođru sınıflandırılan veri sayısı
<i>TVS</i>	Toplam sınıflandırılan veri sayısı
<i>TBA</i>	Temel bileşen analizi
<i>k-EYK</i>	k-En yakın komşu
<i>KA</i>	Karar ağaçları
<i>DAA</i>	Dođrusal ayırım analizi
<i>DVM</i>	Destek vektör makineleri
<i>STY</i>	Sınıflandırıcı toplulukları yöntemi
<i>PKA</i>	Pearson korelasyon analizi
<i>KBÖS</i>	Korelasyon bazlı öznitelik seçici
<i>UOB</i>	Uçucu organik bileşik
<i>AIYS</i>	Ardışıl ileri yönlü seçme
<i>AGYS</i>	Ardışıl geri yönlü seçme
<i>IIR</i>	Infinite Impulse Response
<i>FIR</i>	Finite Impulse Response

## 1. GENEL BİLGİLER

### 1.1. Giriş

Son yıllarda yapılan çalışmalar ve gelişen teknoloji ile birlikte, yapay zekâ ürünü cihazlar ve yazılımlarla biyolojik özelliklere sahip nesnelerin fizyolojik özelliklerinin ölçümü ve de sınıflandırılması yapılmaya başlanmıştır [1]. Bunlardan en önemlilerinden biri ise kokuların algılanması ve bu sayede nesnelerin sınıflandırılması çalışmalarıdır. Bu çalışmalarda ortaya çıkan elektronik cihaz ise, elektronik burundur.

Elektronik burun, dünya üzerinde var olmuş tüm yaşam formlarında çeşitli fizyolojik özellikleri bulunan koku alma organlarının gelişen teknoloji ile birlikte, elektronik devre elemanları yardımıyla gerçekleştirilmiş bir modelidir. Bu model sayesinde basit ya da karmaşık koku türleri çeşitli elektronik burun dizaynları ile algılanıp ayırt edilebilmektedir.

Elektronik burun düzenekleri, içerisinde bulunan sensörler sayesinde dış dünyadaki kokuları algılayıp, bileşenlerine ayırt edildikten sonra hangi nesneye ait olduğuna karar verebilirler. Ya da bir başka deyişle nesnelerin havaya yaydığı kokuların hangi bileşenlerden meydana geldiğini ortaya koyabilirler. Bu sayede koku ile ilgili ayrıntılı bilgiler elde edilebilmektedir.

Canlılarda bulunan biyolojik koku algılama sistemi herhangi bir kokuya uzun süre maruz kaldığında duyu almaçlarında oluşacak yorgunluktan dolayı bu kokuyu algılayamaz. Ancak elektronik burun, herhangi bir yorgunluk ya da çevresel etkiden etkilenmeyeceği için sürekli olarak hassas ölçümler yapabilmektedir [2].

Elektronik burun yakın zamanda ortaya çıkmasına rağmen birçok alanda etkili olarak kullanılmaktadır. Bu alanlardan başlıca olanları ise; yiyecek-içecek endüstrisi, askeri savunma sanayisi, tıbbi araştırma çalışmaları, otomotiv ve uzay teknolojileri vb. gibi alanlardır.

Elektronik burun ile otomotiv alanında yapılan bazı çalışmalarda; arabaların gaz emisyonunun ölçümünü, doğal gaz ile çalışan arabalarda gaz sızıntısı olup olmadığını, araç içinde klima etkisiyle havanın solunabilir olup olmadığı gibi değerlerin ölçümü yapılabilmektedir [3].

Elektronik burun sayesinde kozmetik endüstrisinde parfümlerin değerlendirilmesi ve aromalarının ayırt edilmesi sağlanmıştır. Parfümlerin kararlılığı elektronik burunlarla incelenmiştir. Dolayısıyla üretilen parfümlerde belirli bir standart nokta oluşturulması amaçlanmıştır [4].

Bazı çalışmalarda hareket edebilen bir cihaz ile elektronik burun kullanılarak koku kaynağını tespit edip yönelebilen bir cihaz geliştirilmiştir. Bir başka cihazda ise koku taklidi üzerine çalışılmıştır. Elektronik burun entegre edilmiş bu cihaz kokuyu algılayıp benzer bir koku üreterek bulunduğu ortama yaymaktadır [5].

Endüstride ve tarımsal faaliyetlerde üretim sonucu ortaya çıkan zararlı atıkların atmosfere salınımı yakın atmosferi ve dünya genelindeki dengeyi bozucu yönde etki etmektedir. Havaya karışan zararlı gazlar, bu havayı soluyan canlıları bir yandan zehirlerken, yağmurla havadaki atıkların toprağa ve suya karışması sonucunda çevresindeki tüm canlıları da adım adım yok etmektedir. Zararlı bu faaliyetlerin denetiminde ve çevre sağlığının korunmasında yine elektronik burun kullanılmaktadır [6].

Elektronik burun sağlık alanında da önemli bir yere sahiptir. Birçok hastalık insan vücudunda oluşmaya başladığında çeşitli belirtiler ortaya çıkarmaktadır. Bu belirtiler; ağrı, ateş yükselmesi, halsizlik, uyuşukluk vb. şekillerde olabilir. Ancak bunlara benzer belirtiler bazı hastalıkların belirlenmesinde kullanılabilirken, erken teşhisinde hayat kurtaracak birçok hastalığı ise ortaya çıkarmamaktadır. Bunun sonucunda ise geç teşhis ile beraber tedavi edilmediği için hastanın hayatı sona ermektedir. Tüm bu olası durumlardan kaçınmak için erken teşhis önemlidir. Elektronik burunun sağlık alanında kullanılması ile bazı hastalıkların insan vücudunda oluşmaya başladığı dönemde vücut kokularının değiştiği keşfedilmiştir. Birçok belirti ortaya çıkmadan önce vücut kokusundaki değişiklikler bazı hastalıklar için ön bilgi ve erken teşhis imkânı sağlamaktadır. Erken teşhisi ile tedavi edilebilen hastalıklar sonucunda insan hayatı korunup daha kaliteli ve uzun yaşaması sağlanmış olmaktadır. Benzer olarak yapılan bazı çalışmalarda şeker hastalarının kan şekerleri yükseldiğinde nefeslerindeki keton bileşeninin miktarının aşırı arttığı ortaya çıkmıştır. Bu bilgiler ışığında ise gerekli önlem ve müdahaleler yapılabilir [7].

Elektronik burunun en yaygın kullanıldığı alanlardan birisi de yiyecek-içecek sektörüdür. İnsanların sıklıkla tükettiği hazır gıdalarda çıkabilecek sorunlar insan hayatını tehlikeye attığı için üretim süreçlerinin dikkatle incelenmesi gerekmektedir. Bazı dönemlerde ülkelerde yaşanan salgın hastalıkların ya da toplu zehirlenmelerin sebebinin benzer üretim hataları yüzünden ortaya çıktığı çok geç anlaşılmıştır. Elektronik burunlar




sayesinde yiyecek içecek maddelerinin üretiminde daha dikkatli olunması sağlanmıştır. Bu sayede daha önce yaşanmış benzer vakaların ortaya çıkmasının da önüne geçilmiş olur. Sıklıkla içecek olarak tükettiğimiz çay, üretiminden tüketimine kadar geçen süreçte bir dizi kontrollerden geçer. Bunların en önemlileri, fabrikalarda çaylar tüketime uygun hale getirilirken yapılır. Üretim sürecinde insanlara ait biyolojik koku algılama sistemi kullanıldığı için yapılan bu çalışmalarda hata riski çok fazla olmaktadır. Dünya üzerinde yapılan bazı çalışmalarla birlikte insanın biyolojik koku algılama sistemi ortadan kaldırılarak, yerine elektronik burun sisteminin koyulması için çalışmalar yapılmaktadır. Hatta bu konuda elektronik buruna ek olarak elektronik dilde kullanılmaktadır. Yapılan çalışmalarla ortaya çıkan sonuçları incelendiğinde oldukça başarılı sonuçlar elde edildiği görülmektedir [8-15].

Bu tez çalışmasında, ülkemizde Doğu Karadeniz’de üretilen ve yalnızca bu yöreye özgü, günlük hayatta sıklıkla tükettiğimiz, sıcak ya da soğuk türleri de bulunan bir içecek olan çaylar üzerinde çalışılmıştır. Bu çalışmadaki amaç, birbirinden farklı 6 çeşit çay ürününün elektronik burun yardımıyla birbirinden ayırt edilebilmesinin incelenmesidir. Bu incelemenin sebebi ise, çay fabrikalarında çay ayırt etme işleminin çay tadımı yapan uzmanlar tarafından sürekli olarak doğru bir şekilde yapılamıyor olmasından kaynaklanmaktadır. İnsan duyularının çoklu denemelerde yorulacağı ve hata riskinin yüksek olabileceği göz önüne alındığında, bu çalışma sayesinde herhangi bir yorulma söz konusu olmaksızın tamamen otokontrolü olan makineler sayesinde sürekli aynı standartlarda üretimler yapılması hedeflenmiştir.

## 1.2. Koku Uzayı

Koku uzayı, ilk zamanlarda ünlü bilim insanı C. Linnaeus tarafından 1752 yılında kokuların 7 çeşit olarak ayrılmasıyla oluşturulmuştur. Bu kokular; ıtırılı (fregant), güzel kokular (ambrosial), sarımsak ve soğan kokuları (alliacous), keçi kokusu (hircine), iğrenç kokular (repulsive) ve mide bulandırıcı kokulardan oluşmaktaydı [16]. 1916 yılına gelindiğinde ise bir başka bilim insanı olan Henning birincil kokular üzerine olan çalışmasıyla kokuları tanımlamaya ve ayırt etmeye çalışmıştır. Şekil 1’de görülen 6 köşeli prizmadan yararlanan Henning; çürük kokuları (putrid), ıtırılı kokular (fregnant), baharatlı kokular (spicy), çam sakızı kokusu (resinous), yanık kokusu (burned) ve hafif kokuları (ethereal) birbirinden ayırt etmeye çalışmıştır [17].



Şekil 1. Henning Piramidi [17].

Henning yaptığı bu çalışmasında, kullandığı tüm kokuları prizmasının köşelerine tam olarak yerleştiremediği için başarıya ulaşamamıştır. Bu yüzden tercih edilmeyen Henning'in yöntemi bilim insanlarını başka yöntemler araştırmaya yöneltmiştir. Yapılan diğer çalışmalardan biri de Woskow ve Shiffman tarafından geliştirilen, çok boyutlu ölçekleme yöntemi ile kokuların analizidir [18]. Bir başka çalışmada ise Chee-Ruiter iki farklı kokunun birbirleriyle ne kadar benzeyip benzemediğini (1) denklemindeki formülle ispat etmiştir.

$$I = P(A|B).P(B|A) \quad (1)$$


(1) denkleminde I ile verilen ifade; A ve B kokuları arasındaki ölçüm bilgisinin birbirine yakınlığıdır [18].

### 1.3. Biyolojik Koku Algılama Sistemi

Biyolojik koku algılama sistemi, tüm canlılarda ortak olarak bulunan koku alıcı reseptörlerden oluşan biyolojik bir sistemdir. Bu sistem sayesinde canlılar doğada bulunan ve koku yayıcılar tarafından havaya yayılan uçucu organik bileşenlerini (UOB) algılayabilirler. Bu sayede alıcı canlılarda kokulara karşı belirli bir duyarlılık ve hassasiyet oluşur. Örneğin canlılar kokulardan tehlikeleri, yaşam alanlarını, yiyecek-içeceklerin zehirli olup olmadığını, hangi eşlerin kendilerine uygun olup olmadığı gibi bir sürü özelliği algılayıp buna göre yaşamlarını yönlendirmektedirler.

Biyolojik koku algılama sistemi her canlı türünde farklılık göstermektedir. Buna bağlı olarak canlı gruplarında bulunan biyolojik koku algılama sistemleri, o canlı türünün günlük yaşamında en çok kullandığı özellik türüne bağlı olarak özelleşmiştir. İnsanlar kokularından yemeklerin lezzetli olup olmadığını anlayabilirken, hayvanlar ise kokladıkları nesnenin kendilerine uygun bir besin maddesi olup olmadığını anlayabilmektedirler.

İnsanlarda bulunan biyolojik koku algılama sistemi ise Şekil 2’de görüldüğü gibidir. Bu biyolojik koku alma duyusu yaklaşık olarak 10.000’in üzerinde farklı koku molekülünü birbirinden ayırt edilebilecek şekilde meydana gelmiştir.



Şekil 2. İnsanda bulunan biyolojik koku algılama sistemi [20].

İnsanlarda bulunan koku algılama sistemi koku algılama hücrelerinden meydana gelirler. Koku algılama hücreleri ise genel olarak 3 ana bölümden meydana gelmektedirler. Bunlar koku reseptörleri ve sinir aksonlarıdır.

Koku alma işlemi, koku moleküllerinin burun boşluğundan içeri girerek geniz boşluğu üzerinde yer alan koku reseptörlerine tutunması ile başlar. Sonra ise sinir aksonları ile koku soğancığına iletilmesi ile yoluna devam eder. Koku soğancığında belirli işlemlerden geçen koku bilgisi daha sonra beyine ulaşır. Beyinde ise işlenerek bu bilgiden anlam çıkarılır.

Bir kokunun var olduğu bir ortamda bulunan insan sürekli aynı kokuya maruz kaldığı için biyolojik koku algılama sistemi zamanla yorulur ve bu kokunun artık alınmadığı bilgisini beyine gönderir. Bu durumun oluşmasındaki temel sebep koku soğancığına gelen koku bilgisinin beyni fazladan çalışarak yormaması için aldığı bir önlemdir.

Koku içeren UOB'ler yaklaşık olarak 300 dalton'dan daha küçük bir kütleyle sahiptirler. Öyle ki, bilinen en büyük kokulu madde yaklaşık olarak 296 dalton'luk kütleyle Labdane'dir.

UOB; organik asitler, aldehitler, alkoller, amitler, esterler, organik asitler, aminler, eterler ile karışık gazlar, ketonlar, hidrokarbonlar, nitriller, fenoller, nitrojen ve sülfür içerikli bileşiklerden meydana gelirler.

#### **1.4. Elektronik Burun**

Elektronik burun, gelişen teknoloji sayesinde biyolojik koku alma sistemine benzeyen bir yapının oluşturulması fikri ile ortaya çıkmıştır. Elektronik burun ilk başlarda basit bir model olarak ortaya çıkmışsa da zaman içerisinde ihtiyaçlara ve araştırmalara bağlı olarak daha kompleks bir yapıya dönüşmüştür.

Elektronik burunun ortaya çıkmasındaki temel fikir, insan beyninin yapısı gereği, burun yoluyla algıladığı kokuları tamamen ayrıntılı olarak bileşenlerine ayrıştırılamıyor olmasıdır. Bu sebepten dolayı oluşturulan elektronik burun ile bu eksiklik giderilmeye çalışılmıştır. Elektronik burunlar yapılarında bulunan elektrokimyasal sensör dizileri sayesinde bulunduğu ortamdaki UOB'den ne kadar ve hangi oranda bulunduğunu tespit edebilirler.


Elektronik burunda, insanlarda bulunan burundaki koku reseptörleri yerine kimyasal sensörler, koku soğancığı yerine ise de yapay sinir ağları kullanılmaktadır.

Günlük yaşamımızda basit elektronik burunlar sıkça kullanılmaktadır. Özellikle insan sağlığını tehdit eden unsurların ortadan kaldırılmasında bu cihazlar sayesinde önemli mesafeler kat edilmiştir. Bu cihazlar kullanım yönüyle; evlerde ve sanayi tesislerinde gaz kaçaqlarının algılanması ve uyarı sistemlerinin çalışmasında, insan nefesinden hastalık

tahmin edilmesinde, yer altı kaynaklarının tanımlanmasından gökyüzündeki gaz bileşenlerinin yoğunluklarının ölçümüne kadar çok geniş bir alanı kapsar.

Elektronik burun çalışmaları ilk olarak 1970 yılında Warwick Üniversitesinde başlamıştır. İlk elektronik burun prototipi ise 1993'te ortaya çıkmıştır. 1993'ten bu yana süren çalışmalar sayesinde ihtiyaçlara uygun farklı türde birçok elektronik burun üretilmiştir.

Standart yapıdaki bir elektronik burunun çalışma yapısı Şekil 3'te gösterildiği gibidir.



Şekil 3. Standart yapıdaki bir elektronik burunun çalışma sistemi [21].

Şekil 3'te de görüldüğü üzere elektronik burun 4 aşamada koku bilgisine dair elde etmek istediğimiz sonuçları vermektedir.

1. aşamada kokunun sensör dizisi tarafından algılanması işlemi yapılır. Bu işlem koku örneğinin ortamdan izole olan sensör kabına pompa vasıtasıyla itilmesi ile başlar. Burada bulunan birçok elektrokimyasal sensör, farklı türdeki UOB'ler ile kimyasal olarak reaksiyona girerler. Bu kimyasal reaksiyon sonucunda sensörler üzerindeki elektriksel değerlerin (direnç, gerilim vb.) değişimine yol açarlar. Değişiklik gösteren bu özellikler sayesinde sinyal işaretlerinin oluşması sağlanarak bilgi taşıyıcı işaret oluşturulur.

2. Aşamada sensör dizisinden gelen işaret sinyallerinin, bilgisayara bağlı bulunan veri elde etme kartı yardımıyla bilgisayara kayıt edilmesi sağlanır.

3. Aşamada kaydedilen işaret sinyallerinin karmaşıklığından kurtulması için üzerinde bazı düzeltmeler ve değişiklikler yapılır. Bunlar; filtreleme, yükseltme, fark alma, normalize etme vb. gibi işlemlerdir.

4. Aşamada, 3. aşamada işlenen sinyalin örüntü tanıma yöntemleri kullanılarak anlamlandırılmasına çalışılır. Anlamlandırma işlemi örüntü tanımaya en uygun

algoritmaların seçilmesi ve uygulanması ile son bulur. Bu anlamlandırmanın sonucuna göre ise elektronik burun ile ölçülen kokulara ait bilgiler elde edilmiş olur.

4. aşamada kullanılan algoritmalarından sadece biri değil, aynı zamanda birçoğu bu örüntünün tanınmasında etkili olabilir. Buna karar verebilmek için öncelikle verinin özelliklerinin yeterince anlaşılması gerekir. Seçilen algoritmalar ile yapılan örüntü tanıma işlemleri sonrasında, algoritma uygulama sonuçları arasında kıyaslamalar yapılarak en uygun algoritma ile en uygun sonuç elde edilmiş olur.

#### 1.4.1. Algılayıcı Birim

Elektronik burnu oluşturan elemanlar içerisinde en önemli kısım algılayıcı birimdir. Algılayıcı birim bir dizi sensörden meydana gelmektedir. Bu sensörler sayesinde koku moleküllerinden koku sinyalinin alınması sağlanır. Sensörler, alınması istenen koku sinyalinin özelliğine uygun olarak seçilmelidir. Her sensör yalnızca bir veya birkaç tipte kokunun algılanmasına uygun olarak üretilmiştir.

Elektronik burun içerisinde bulunan algılayıcı birimde elektrokimyasal sensörler kullanılabildiği gibi aynı zamanda ısı sensörler, optik sensörler, gravimetrik sensörlerde istenilen bilgilerin edinilmesinde kullanılabilir [22]. Elektronik burun ile kullanılan sensörler ve bazı özellikleri Tablo 1’de verilmiştir. Tablo 1’de verilen bazı kısaltmalara ait isimlerin açıklamaları şu şekildedir; Metal oxide semiconductor (MOS), Conducting polymer (CP), Karbonmonoksit (CO), Metal oxide semiconductor field effect transistor (MOSFET), Surface plasmon resonance (SPR), Quartz crystal microbalance (QCM), Complementary metal oxide semiconductor (CMOS) ve Surface acoustic wave (SAW)’dır.

Tablo 1. Elektronik burun uygulamalarında kullanılan sensörlere ait özellikler [22]

Sensör Tipi	Ölçülen Büyüklük	Etkileşim Yönü	Kullanım Bilgisi
MOS	İletkenlik Değeri	Kimyasal Etki	Maliyeti ucuzdur. Yüksek sıcaklıklarda daha verimli çalışır.
CP, CO	İletkenlik Değeri	Kimyasal Etki	Oda sıcaklığında verimli çalışır

Tablo 1'in devamı

MOSFET	Akım-Gerilim Değeri	Kimyasal Etki	CMOS tabanlı kimyasal sensörlere entegre edilebilir. Ancak etkilere geç cevap verir.
Polimer	Kapasite Değeri	Kimyasal Etki	CMOS tabanlı kimyasal sensörlere uygulanabilir. Ancak neme karşı aşırı hassastır.
Şotki Diyot	Gerilim Değeri	Kimyasal Etki	CMOS tabanlı kimyasal sensörlere uygulanabilir ve entegre edilebilir. Ancak Altın, Platin ve İridyum gibi pahalı maddelere gereksinim duyar.
Elektro-Katalitik	Akım Değeri	Kimyasal Etki	Elektriksel Gürültüden etkilenmez. Ancak boyutları optimum kullanım için fazla büyüktür.
Termokupl, Pelistör, Termistör	Sıcaklık Değeri	Isı Etkisi	Düşük maliyetlidir. Oluşan etkilere geç tepkime verir.
SPR	Işığın Kırılma Değeri	Optik Etki	Yüksek Maliyetlidir. Kullanımı oldukça kolaydır.
Floresans	Yoğunluk Değeri	Optik Etki	Yüksek Hassasiyete Sahiptir. Ancak sınırlı bir ışık kaynağı vardır.
QCM (BAW), SAW	Piezo-Elektrik	Gravimetrik Etki	Düşük maliyetlidir. Arayüz elektronığının kullanımı zordur.

#### 1.4.1.1. Sensörler

##### 1.4.1.1.1. Elektrokimyasal Sensörler

Elektrokimyasal sensörler, elektronik koku algılayıcı devrelerde sıklıkla kullanımına başvuru alan elemanlardır. Ucuz olmaları, elektriksel gürültüden etkilenmemeleri, CMOS gibi kimyasal sensörlere uygulanabilmesi yönüyle tercih edilirler. Ancak neme karşı çok hassas olmaları en büyük dezavantajlarıdır.

Elektrokimyasal sensörler, üzerlerinde barındırdıkları iletken olan elementlerin koku moleküllerindeki kimyasal bileşenlerle tepkimeye girmesi sonucu iletkenliklerinin değişmesi ile çalışmaya başlarlar.

Ticari olarak ilk üretilen elektronik burunlarda polimer bazlı sensörler kullanılmaktaydı. Diğer elektrokimyasal sensörler ile aynı şekilde çalışan polimer bazlı sensörler, UOB'nin sensör direncini değiştirmesi esasına dayalı çalışmaktadır. Bu tarz sensörlerde genellikle polipirol, polianilin, politiyofen ve poliasetilen organik bileşikleri kullanılmaktadır. Polimer bazlı sensörler 0.1 ile 100 ppm (milyonda bir, part per million) değerleri arasında çok hassas ölçümler yapabildiği için tercih edilir. Ancak sensör üzerinde biriken nem ve sensör kaymaları sensör ölçümlerini olumsuz etkilediği için uzun süreli kullanımlarda etkili değildir [37].

Elektronik burunlarda kullanılan bir başka sensör türü ise MOSFET tipi sensörlerdir. Bu tip sensörler ilk üretilmeye başlandığı yıllarda sadece Hidrojen gazının analizlerinde kullanılıyordu [1].

MOSFET tipi sensörlerde oksit yalıtkan olarak silisyum oksit ( $\text{SiO}_2$ ) kullanılmaktadır. Üzerinde sürekli olarak bir akım hareketliliği olan sensörün, UOB ile tepkimeye girmesi sonucunda direnç değerinde değişimler meydana gelerek sensörlerin verilen kokuya ait bilgi sinyali oluşturması sağlanır. MOSFET tipi sensörler yaklaşık olarak  $150\text{ }^\circ\text{C}$  sıcaklığa kadar çalışabilmektedir. Gelişen teknoloji ile birlikte sensörlerin boyutları da zamanla küçülmeye başlamıştır. Ayrıca MOS tipi sensörler silikon tabanlı sensörler ile kıyaslandığında çok daha yüksek sıcaklıklarda çalışabilirler.

Elektronik burunlarda genellikle değişen gerilim değeri ile ölçüm yapan sensörler kullanılır. Ancak akıma bağlı olarak çalışan sensörler de vardır. Bu tip sensörler, sabit gerilim altında akım değerinin değişmesine bağlı olarak ölçüm sonuçları elde edilir. Akım değerleri ise bu sensörlerde 1 ppm kadarlık bir gaz yoğunluğunda, piko ile mikro amper seviyelerinde akım akıtır. Akıma bağlı çalışan sensörlerde çoğunlukla altın (Au) ve platinyum (Pt) elementleri kullanılır. Bu tip sensörler genellikle  $\text{SO}_2$ ,  $\text{NO}_2$  ve  $\text{CO}_2$  gazlarının analizinde kullanılır. Kullanım ömürlerinin uzun olması ve düşük maliyeti sebebi ile daha çok tercih edilir [1].

Bu tezde anlatılan çalışmalarda genellikle kokunun oluşturduğu kimyasal etki ile sinyal üretebilen elektrokimyasal sensörlerden biri olan MOS tipi sensörlerden faydalanılmıştır.

MOS tipi sensörler elektronik burun uygulamalarında sıklıkla tercih edilen bir sensör türüdür. MOS tipi sensörler 1968 yılında Taguchi tarafından ticari faaliyetlerde kullanılmak üzere meydana getirilmiştir [34].



MOS tipi sensörlerin iç yapısında kalay oksit ( $\text{SnO}_2$ ), paladyum (Pd), platin (Pt) gibi elementler kullanılmaktadır. Bu elementlerden biri olan kalay oksit büyük oranda kullanılırken, diğer elementler ise katkı maddesi olarak ölçülmek istenen koku değerine göre değiştirilerek kullanılır. Diğer MOS tipi sensörlerde ise kalay oksitin yerine çinko asit ( $\text{ZnO}$ ), tungsten oksit ( $\text{Wo}_3$ ) veya titanyum oksit ( $\text{Tio}_2$ )' de kullanılmaktadır. MOS tipi sensörlerin dışı ise adını aldığı Metal Oksit ile kaplıdır [32].

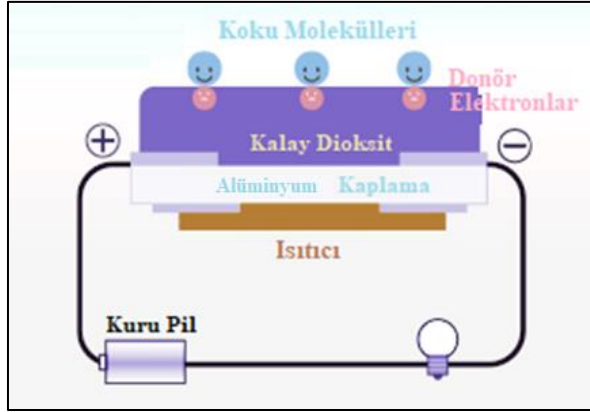
MOS tipindeki kimyasal sensörlerin sinyal üretmeye başlaması, bir dizi sıralı işlem sonucu meydana gelir. MOS sensörleri üzerinde bulunan; Kalay Dioksit, Alüminyum kaplama, ısıtıcı ve güç kaynağı koku haznesindeki oksijenin hareketlerinden etkilenir.

İlk durumda, ortama koku verilmeden önceki kısımda, ortamda bulunan saf oksijen atomları, kalay dioksit'te bulunan molekülleri kendilerine çekerek sensör üzerindeki elektron akışına engel olur. Hareket etmeyen elektronlar herhangi bir elektriksel aktivite oluşturmadığı için sinyal üretemez. İkinci durumda ortama verilen koku molekülleri ile etkileşime giren oksijen atomları, Kalay Dioksit'te bulunan moleküllerden uzaklaşmaya başlar. Bu anda sensör üzerindeki elektronlar serbest kalarak direncin değişmesine sebep olur. Bundan dolayı sensörden kokunun yoğunluğuna bağlı olarak akım akmaya başlar. Üçüncü durumda ise UOB'yi ortamdaki uzaklaştırmak için ortama saf oksijen verilir. Son temizleme aşamasında kokunun ortamdaki oksijen vasıtasıyla çıkarılmasıyla birlikte oksijen atomları tekrar kalay dioksit'e tutunarak üzerindeki elektronların hareket etmesini engelleyerek sensörün direncini yükseltir. Bu sayede akım akmasını engellenir. Buna bağlı olarak sensörler ilk durumlarına geri dönerler. Her bir kullanımda tekrar aynı döngü tekrarlanır.

Şekil 4'te MOS sensörün iç yapısı gösterilmektedir. MOS sensörün içerisinde; kalay dioksit, ısıtıcı, alüminyum kaplama ve kuru pil bulunmaktadır.

MOS tipi sensörlerde bulunan ısıtıcı sensörün çalışması için gerekli sıcaklığı sağlarken, kuru pil ise devreye gerekli gücü sağlar. MOS sensörleri yaklaşık olarak 300 ile 500 °C derece arasında çalışabilir. Bu yüksek sıcaklıklar sayesinde, tepkimeler esnasında oluşacak nemin, sensöre zarar verme riski ortadan kaldırılır.

Sensörlerin hassas ölçümler yapabilmesi için gerekli sıcaklık değerine tam olarak ulaşmış olması gerekir. Çünkü sıcaklığı yeterince iyi ayarlanamamış sensörlerde tamamen doğru ölçüm sonuçlarını elde etmek zordur. Bu nedenle sıcaklığının doğru ayarlanmasına dikkat edilmelidir.



Şekil 4. MOS Sensörün İç Yapısı [23].

Sensörlerin çok fazla ısınması ile çok fazla güç harcaması ise başka bir önemli konudur. Taguchi'nin ilk yaptığı MOS, yüksek sıcaklık değerinde çalıştığı için yaklaşık olarak 750 ila 900 mW arasında güç harcıyordu. Bir ölçüm sensörü için tüketilen güç miktarı fazla olduğundan bu durumun ortadan kaldırılması için birçok çalışma yapılmıştır. Bunlardan en önemlisi ise sensör boyutlarının küçültülmesi gerektiğine karar verilmesi olmuştur. Boyutları küçülen sensörlerin üzerindeki film tabakaları da inceltirilmiştir. Bunun sonucunda da ince film katmanlı sensörler ile yapılan ölçümlerin, kalın film katmanlı sensörler ile yapılan ölçümlerden daha iyi sonuç verdiği ortaya çıkmıştır. İnce film katmanlı sensörlerin hızlı tepki verebilmesi ve boyutlarının da küçük olması ile en optimum kullanım için uygun hale gelmiştir. İnce film katmanlı sensörlerin üretilmesi zorken, kalın film katmanlı sensörlerin üretilmesi ise kolaydır. Tüm bu durumlar ortaya konulduğunda ihtiyaca göre en uygun sensör seçimi rahatlıkla yapılabilir.

#### 1.4.1.1.2. Isıl Sensörler

Isıl sensörler genellikle yanıcı gazların algılanmasında kullanılan gaz algılayıcı sensörlerden biridir. Isıl sensörler; pelistör, yanıcı gaz sensörü ya da katalitik çubuk olarak da adlandırılır. Isıl sensörlerin yapısı, bir seramik tabakanın içerisinde geçen platin bir telden oluşmaktadır. Ölçümlerde platin telin üzerindeki direnç değişiminden faydalanılmaktadır [24]. Isıl sensörler metan, organofosfor, etan, hidrojen, propan gibi birçok yanıcı gazın etkisi ile çalışmaktadır. Isıl sensörler, yüksek oranda gaza maruz kaldıklarında sensör üzerinde oluşan ısı ve oksidasyon gibi diğer etkilerden

etkilenebilecekleri için performansları değişebilmektedir. Isıl sensörler oksidasyon ile çalıştıkları için çoğunlukla %12'lik bir oksijen yoğunluğunda çalışması gereklidir [25].

Isıl sensörlerin içerisinde bulunan devrede direnç değişimleri ısının etkisiyle olur. Bu da sensörlerdeki Wheatstone köprüsünün dengesinin bozulmasına, dolayısıyla da sensörlerin sinyal üretmesini sağlar.

#### **1.4.1.1.3. Optik Sensörler**

Optik sensörler kokuların ölçümünde kullanılabilen sensör türlerinden biridir. Optik sensörler; lazer, kızılötesi (infrared) ve fiber optik sensörler olmak üzere toplamda 3 çeşittir.

Kızılötesi sensörler ortamdaki sıcaklık farkını ölçerek çalışmaktadır. Ortamda bulunan koku molekülleri arasında bulunan bağlar sabit bir frekansta salınım yaparlar. Ortama verilen kızılötesi ışın ile birlikte, koku molekülleri etkileşime girerek frekanslarının bir kısmını eşit hale getirir. Eşit hale gelen frekanslardan bazıları atomlar arasındaki bağlarda absorbe edilir. Ancak absorbe edilen enerji, UOB'de daha fazla enerji kazanarak aktif bir şekilde titreşmeye başlar. Aktif şekilde titreşen atomlar ortam sıcaklığını belirli ölçülerde yükselterek sıcaklık farkını meydana getirir. Bu sıcaklık farkı sensör tarafından tespit edildiğinde ise kokuya ait sinyal bilgisi elde edilir [26]. Kızılötesi sensörlerde, kaynak atmosferi bir filtreden boşalacağı için tepki süresi uzar. Tepki süresi ısıl sensörlerle karşılaştırıldığında daha uzundur. Kızılötesi sensörlerin bir diğer dezavantajı ise neme karşı dayanıksız olmasıdır. Bu tip sensörlerin avantajı ise oksijenden bağımsız olarak doğru ölçümler yapabilmesidir.

Lazer sensörleri, ortamdaki UOB'ler üzerine lazer diyottan bir ışın demeti göndererek, gazın ışık tutma absorpsiyonundan faydalanır. UOB'den geri yansıyan lazer ışığının fotodiyota gelmesi ile ölçümler yapılır. Lazer sensörleri ile bir UOB karışımındaki gazların konsantrasyonunu ölçmek mümkündür [27].

Fiberoptik sensörler, ışının parametre değişiminden faydalanarak ölçümler yapmaktadır. Polianilin, Polipropil veya politiyofen gibi iletkenler çeşitli gazlarla etkileşime girdiklerinde dirençlerinde bir değişim gözlenir. Dirençlerde meydana gelen bu değişimle iletkenlikte oluşan bu değişim kırılma indeksinde de değişikliklere sebep olur. Kırılma indeksinin değişmesi ile fiberoptik hatta meydana gelen optik değişikliklerin sonucundan faydalanılarak ölçümler yapılabilir. Fiber optik sensörler küçük yapıları, yüksek hassasiyetleri, elektromanyetik etkilere dayanıklılık gibi özelliklere sahiptir [28,29].

#### 1.4.1.1.4. Gravimetrik Sensörler

1880 yılında Curie kardeşler tarafından, kuvars üzerine uygulanan herhangi bir basınç ile iki yüzey arasında bir elektrik alanı oluşturduğunu keşfedilmiştir. İlerleyen dönemlerde bu teknikle yapılan ölçümlerle ise hassasiyetin git gide arttığı gözlemlenmiştir. 1g ağırlıktan 1pg ağırlığa kadar çeşitli ağırlıkların etkisiyle ölçümler yapılmıştır.

Gravimetrik sensörler, ortaya çıkışları ile birlikte birçok farklı UOB'nin ölçümünde kullanılmıştır. Gaz algılamasını sağlayan sensörler; Kütle Ses Dalgası, Bükülgen Plaka Dalgası ve Yüzey Ses Dalgası sensörleridir.

Kütle ses dalgası sensörleri, içerisinde bulundurduğu kristalin üzerinde biriken kokuya ait UOB'nin ağırlığı ile üzerinde bulunan kristalin frekansının değişiminden faydalanarak ölçüm yapmayı sağlar. Kütle ses dalgası sensörlerinde her 1 ng kütle değişiminde yaklaşık kristal de 1 Hz'lik değişim meydana gelir. Kütle ses dalgası sensörleri genellikle, QCM ya da kalınlık makas modu sensörü olarak da adlandırılır.

Bükülgen plaka dalgası sensörleri, bükülgen bir karakteristik ve simetrik olmayan Lamb dalgalarını kullanır. Yüzey ses dalgaları ile benzer yapıdadır. Her ikisi de Inter Dijital Transduser'lerden ve polimer kaplı geciktirme hattından faydalanırlar. Lamb dalgaları akustik tabaka üzerinden yayılarak çalışırlar [30]. Bükülgen plaka dalgası sensörleri diğer sensörlere kıyasla daha az karmaşık devre yapısı, daha düşük gürültü seviyesi, daha hassas ölçümler yapması ve daha düşük frekanslarda çalışabilmesi bakımından daha verimlidir.

Yüzey ses dalgası sensörleri, piezoelektrik kristalin dışlı elektrot sistemi ile uyarılması ile harekete geçerler. Yüzey ses dalgası sensörleri ince bir filmle kaplıdır. Bu filmde tutunan koku moleküllerinin kütle değişimi meydana getirmesi esası ile çalışır. Yapılan ölçümlerde titreşim frekansındaki kaymalar göz ardı edilir [31].

#### 1.4.2. Dönüştürücü Birim


Dönüştürücü birim, elektronik burun sensörleri tarafından algılanan UOB'ye ait bilginin, sensörlerden alınarak dijital işarete dönüştürülmesi işlemini yapar. Birçok UOB için kullanıma bağlı olarak sensör çeşitleri ve dönüştürücü birim devreleri çeşitlilik göstermektedir.

Elektronik burun devresinde sensörler üzerinde meydana gelen direnç değişimi, gerilim değişimi vb. gibi büyüklükleri elde etmek için sensörlerde yapılan işlemlerde

Wheatstone köprüsü, alternatif akım empedans spektroskopisi devresi ve gerilim bölücü devreleri kullanılmaktadır [23]. Elektronik burun cihazlarında kullanışlı ve basit olduğundan dolayı genellikle gerilim bölücü devreleri kullanılır. Wheatstone köprüsü yüksek kazancından dolayı sensörlerin, düşük direnç değişimleri ürettiği devrelerde tercih edilir.

Arayüz devrelerinde direnç kontrollü osilatörler de sıklıkla kullanılmaktadır. Sensörlerin kokular ile etkileşerek ürettiği farklı direnç değerleri için farklı işaretler üretmesi ancak direnç kontrollü osilatörlerle olmaktadır. İhtiyaç duyulması halinde kullanılması verimi artırır [33].

Bu çalışmada, metal oksit sensör verileri Şekil 5'te gösterilen gerilim bölücü arayüz devresi ile elektriksel işarete dönüştürülmüştür.



Şekil 5. MOS gerilim bölücü arayüz devresi

### 1.4.3. Elektronik Birim

Elektronik birim, elektronik burun sistemlerinde dönüştürücü birimden alınan elektriksel bilginin bilgisayarda işlenebilmesi için gerekli ön düzenlemelerin yapıldığı birimdir. Bu ön düzenlemeler ile sensörlerden gelen elektriksel işaretin üzerinde hiçbir değişiklik yapılmadan, seçici geçirgen bir yapı ile düzenlemesini sağlar. Elektronik birimin içerisinde ihtiyaca göre; tampon devreleri, yükselteç devreleri ve süzgeç devreleri kullanılmaktadır.

Tampon devreleri, doğru akım devrelerinde kullanılan ara işlem devreleridir. Bu devrelerden yalnızca istenen sinyal bilgisi geçebilir, bunun dışında herhangi bir elektriksel akım tampon devrelerinden diğer bölümlere aktarılmaz.

Yükselteç devreleri daha çok, düşük genlikte elde edilen sinyal bilgisinin, analog-dijital dönüştürücüde işlenebilmesi için uygun genlik seviyesine getirilmesini sağlayan devrelerdir. Düşük genlikteki işaretler analog-dijital dönüştürücüde işlendiğinde elde edilen bilgilerin büyük bir kısmı göz ardı edileceğinden elektronik burun devrelerinde sıklıkla kullanılır.

Sensörlerin ölçüm yaptığı ortamda istenmeyen birçok gürültü işareti de bulunmaktadır. Yapılan ölçümlerin ve alınan bilgilerin doğruluğunun sağlanabilmesi için içerisinde herhangi bir gürültü bulunmayan saf koku bilgisine ihtiyaç duyulmaktadır.

Bu nedenle süzgeç devreleri kullanılır. Süzgeç devreleri, sensörlerden gelen gürültülü sinyalin, gürültü bileşenini filtrelemeye yarar.

Sensörlerden elde edilen verilerde, üretilen koku sinyalini kalibre edebilmek için diğer devrelere ek olarak doğrusallaştırıcı, integral alıcı, türev alıcı vb. gibi devrelerde kullanılabilir [34].

#### **1.4.4. İşaret Koşullama Birimi**

Elektronik burunlarda sensörlerden elde edilen verilerin kullanımı için elektronik birimde yapılan iyileştirmeler tamamen gürültü etkisini ortadan kaldırmaz. Bunu engellemek için alınacak bir diğer önlem ise işaret koşullama birimi altındaki çeşitli filtrelerle sağlanmaktadır. Bu gürültü kaynakları; sensörlerin sürekli çalışmasından kaynaklanan ısı gürültü, elektriksel işaretin devre üzerinden aktarılması sırasında ortaya çıkan iletim gürültüsü, analog- dijital dönüştürücünün kuantalama yaparken ortaya çıkardığı gürültü vb. gibi pek çok kaynak vardır. Bu kaynaklara ek olarak sensörlerde meydana gelen sensör sapmaları ve sensör cevaplarının kararsızlığı da ölçüm sonuçlarını olumsuz olarak etkilemektedir. Bu tür istenmeyen durumları önlemek için elektronik burun devrelerinde çoğunlukla sayısal filtrelerden faydalanılmıştır.

Sayısal filtreler dürtü cevabına göre, IIR (Infinite Impulse Response) ve FIR (Finite Impulse Response) olmak üzere iki çeşittir. Kimyasal ölçümlerde en çok kullanılan filtre tipi sonlu dürtü yanıtı Savitsky-Golay filtreleridir. Birçok uygulamada kullanılan bu filtre tipinde 2. ya da 4. dereceden filtreler kullanılmıştır [35].

### 1.4.5. İşaret Ön İşleme Birimi

Elektronik burun içerisinde bulunan sensörlerin algıladığı UOB, örüntü tanıma evresine geçmeden önce ön işleme biriminde belirli işlemlerden geçer. Bu ön işlemler;

1. Kullanılan sensör çeşidine göre UOB'ye ait elektriksel işaret uygun arayüz devresine girer.
2. Arayüz devresinden alınan işaret, analog işaret işleme evreleri olan tamponlama, filtreleme, kuvvetlendirme devrelerinden geçirilerek sensörlerden gelen bilginin düzenlenmesi sağlanır.

Analog işaret, sayısal işarete dönüştürülerek bilgisayar hafızasında saklanır. Sayısal işaret işleme aşamasında; filtreleme, referans düzeltme, boyut indirgeme ve normalizasyon işlemleri yapılarak, veri örüntü işlemeye hazır hale getirilir [36].

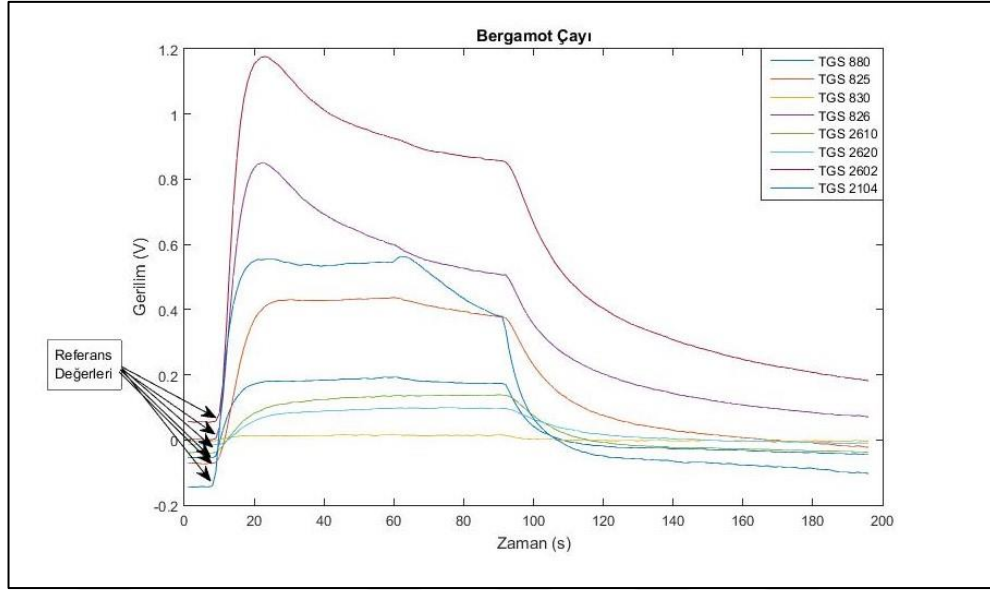
#### 1.4.5.1. Referans Düzeltme

Referans düzeltme işlemi, sensörlerden gelen UOB'ye ait elektriksel bilginin, referans olarak alınan ortam havasına göre düzeltilmesi işlemidir. Deneylere başlamadan önce, daha önce yapılan deneylerden koku haznesi içerisinde kalmış olan farklı UOB'lerin ortamdan uzaklaştırılması için, ortam havası ile hazne temizlenir. Bu sayede hem eski koku molekülleri temizlenmiş hem de sensörlerin hepsi için geçerli bir referans noktası oluşturulmuştur. Şekil 7'de gösterilen grafikte 8 adet MOS sensörden elde edilen Bergamot çayına ait ham sensör verileri görülmektedir.

Şekil 7'de görüldüğü üzere sensörlerden gelen referans gazı ait olan ilk kısımda elektriksel işaretlerde oluşan gerilim seviyeleri arasında farklılıklar görülmektedir.

Bu farkın ortadan kaldırılabilmesi için her bir sensör işaretine, referans düzeltme işlemi uygulanarak aynı koşullar altında değerlendirilmesi sağlanabilir. Bu referans düzeltme işlemi her bir sensörün elde ettiği gerilim değerine aynı şekilde uygulanır.

Referans düzeltme işlemi gerçekleştirilmek için literatürde sıklıkla kullanılan 3 adet yöntem vardır [36].



Şekil 6. Bergamot Çayı'na ait kokunun ham sensör verileri

$$V_{d,k,s} = V_{k,s}(t_{k\ddot{o}}) - V_{k,s}(t_1) \quad \forall d, s, k \quad (2)$$

$$V_{d,k,s} = (V_{k,s}(t_{\ddot{o}}) - V_{k,s}(t_1)) / V_{k,s}(t_1) \quad \forall d, s, k \quad (3)$$

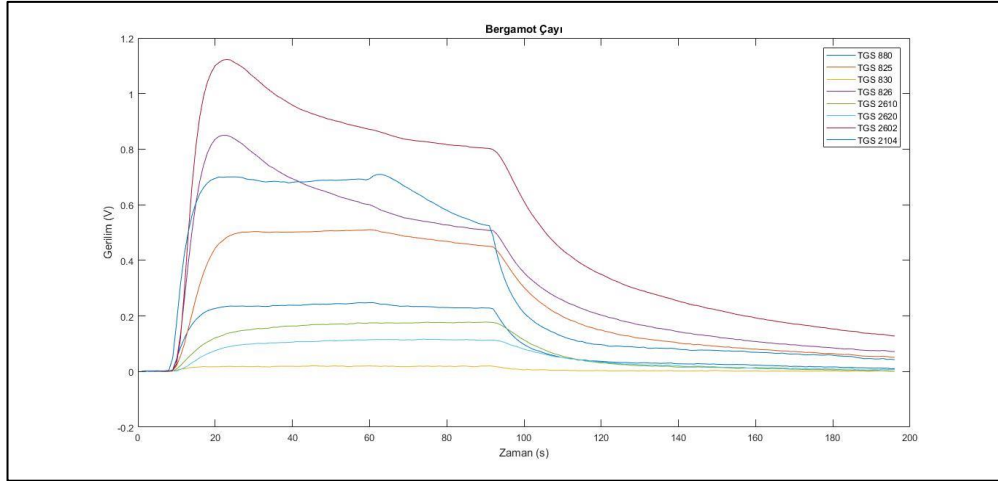
$$V_{d,k,s} = V_{k,s}(t_{\ddot{o}}) - / V_{k,s}(t_1) \quad \forall d, s, k \quad (4)$$

(2), (3) ve (4) denklemleriyle ifade edilen yöntemlerde,  $V_{d,k,s}$  ifadesi referans düzeltmesi uygulanmış işaretin gerilim değerini,  $V_{k,s}(t_{k\ddot{o}})$  ifadesi sensörlerden alınan  $t$  anındaki gerilim değerini,  $V_{k,s}(t_1)$  ifadesi ise sensörden alınan ilk gerilimin örnek değeridir.  $k$  değişkeni veri kümesi içerisindeki koku örneğinin sayısını,  $s$  değişkeni ise sensör sayısını,  $\ddot{o}$  değişkeni ise sensör tepkilerinin toplamdaki örnek sayısını göstermektedir.

(2) denklemi fark alma, (3) denklemi oransal düzeltme ve (4) denklemi ise bağıl düzeltme ile yapılan referans düzeltme işlemlerini göstermektedir.

Yapılan bu çalışmada (2) denklemi ile verilen fark alma denklemi ile referans düzeltme işlemi yapılmıştır. Yapılan referans düzeltme işlemine ait grafik Şekil 7'deki gibi olmuştur.





Şekil 7. Bergamot Çayı'na ait sensör verilerinin referans düzeltme işlemi

### 1.4.5.2. Boyut İndirgeme

Boyut indirgeme işlemi, sensörler sayesinde elde edilen koku bilgisinin çok büyük ve karmaşık olmasından dolayı yapılmaktadır. Alınan koku bilgisi içerisinde ayrılacak sınıflara dair bilginin iyi ayrılabilmesi için veri boyutunun oldukça büyük tutulmasına ihtiyaç vardır. Ancak büyük boyutlu veride işe yaramayan ve kendini tekrarlayan bazı bilgilerin kullanılmaması, işlem yükünün azaltılmasına ve sınıflandırma başarısının artmasına katkı sağlayacaktır. Bu işleme boyut indirgeme adı verilir. Boyut indirgeme işlemleri öznitelik çıkarılmasıyla mümkün olmaktadır. Öznitelik çıkarma işlemi sayesinde veriler içerisinde aynı veriyi en iyi temsil edecek kısımlar kullanılır. Bir başka boyut indirgeme işlemi ise; özneliği çıkarılmış veriye, uygun öznitelik seçme algoritmaları uygulayarak özneliklerin sayısının azaltılması işlemidir [1,38].

#### 1.4.5.2.1. Öznitelik Çıkarma

Kokular kompleks yapıda bulunan uçuculardan meydana gelen gaz halinde bulunan bileşiklerdir. Bu bileşiklerin sensörler tarafından algılanması, buna bağlı olarak da analiz edilmesi esnasında bilgi karmaşası yaşanmaktadır. Çünkü koku türlerinde koku bileşeni sadece tek tip değildir. Birçok farklı atomu da bünyesinde bulundurur. Bazı durumlarda ise istenilen kokuların elde edilmesinde ise birçok koku yayıcı kimyasal madde birbirine karıştırılır. Sadece bir koku türüne tepki veren sensörler var olduğu gibi birden fazla koku

türüne de tepki gösterenleri vardır. İdealde yalnızca belirli koku türlerine tepki vermesi beklenen sensörler, az miktarlarda da başka koku moleküllerine de tepki göstermektedir. Bu gibi durumlarda sensörlerin koku moleküllerinden aldıkları bilgilerde tamamen elde edilmek istenen bilgiye dair veriler bulunmaz. Bunların yanında, etkilendiği farklı koku moleküllerinin, ortam sıcaklığının ve nem gibi diğer koşulların da etkisi bulunur. Bu etkileri ortadan kaldırmak ya da minimize etmek için öznitelik çıkarma yöntemlerine başvurulur.

Öznitelik çıkarma işlemi, karmaşık bir biçimde oluşturulan ham veri kümesinden, verinin aslını temsil eden verilerden oluşan alt kümeler oluşturma işlemidir. Çıkarılan öznitelikler arasından veri ile ilişkilendirilen en iyi öznitelikler seçilerek sınıflandırma yapılması sınıflandırma başarısını yükseltir.

Öznitelik çıkarma işleminin bir diğer amacı ise birbirleriyle çok fazla ilişki içerisinde olan sensör verilerinin birbirinden bağımsız hale gelecek şekilde temsil görüntülerinin oluşturmasıdır.

Literatürdeki öznitelik çıkarma algoritmaları incelendiğinde çoğunlukla şu üç yöntem üzerinde durulur;

- 1) **Parametre Elde Etme Yöntemi:** Bu yöntem, sensörlerden alınan UOB'ye ait elektriksel sinyallerin deney boyunca grafiksel olarak çizdiği şekillerde; yükselme, alçalma, sabit duruma gelme, maksimum noktaya yükselme, minimum noktaya düşme ve eğim yapılan noktalar gibi belirli kısımların incelenerek, her bir koku türünün analizinde ayırt edici faktör olması sağlanabilir. Parametre elde etme yöntemi ile birlikte ortaya çıkan sinyalin incelenmesi ve aynı zamanda uygun ayırt edici parametrelerin seçilerek yeni alt kümelerin oluşturulması sağlanır. Burada fonksiyona bağlılıktan çok görsel olarak ayırt edicilik ön plandadır.
- 2) **Alt Örnekleme Yöntemi:** Sensörlerin UOB ile etkileşmeye başladığı zamanlarda belirli zaman aralıklarından örnek değerleri alınarak yeni öznitelik alt kümelerinin oluşturulması esasına dayanır. Bu sayede örnek boyutu küçültülerek işlem süresi azaltılmış olur.
- 3) **Sistem Tanımlama Yöntemi:** Sensörlerden gelen kokuya ait sinyallerin, oluşturduğu grafikler incelenerek oluşturduğu şekle uygun modellerin uydurulması ile elde edilen parametreler de öznitelik olarak kullanılmaktadır.

Bunun yanında eğri uydurma ya da uydurulan eğriye ait çeşitli parametreler de öznitelik olarak kullanılabilir.

#### **1.4.5.2.2. Öznitelik Alt Kümesi Seçimi**

Öznitelik alt kümesi seçimi, öznitelikleri çıkarılmış verinin içerisinde örüntü tanımada kullanılabilecek en verimli olan kısmın seçilmesi işlemidir. Bu seçim bir öznitelik olabildiği gibi elde edilen özniteliklerin tamamının da kullanılmasını gerektirebilir. Öznitelik alt kümesi seçimi sayesinde öznitelik uzayının boyutu azaltılırken aynı zamanda sınıflandırma için de en uygun özniteliklerin seçimi sağlanmış olur.

Öznitelik alt kümesi seçimlerinde öz nitelik seçimi rastgele yapılabildiği gibi, sistematik şekilde ya da çeşitli algoritmalar sayesinde de yapılabilmektedir. Literatürde pek çok öz nitelik alt küme seçim yöntemi uygulanmıştır. Bunlar içerisinde ilk sırada tüm çıkarılan öz nitelik alt kümelerinin doğrudan kullanılmasıdır. Genel olarak her zaman başarılı şekilde sonuçlar elde edilmese de ilk başvurulan yöntemdir. Diğer bir yöntem ise dal ve sınır arama yöntemidir. Bu yöntem ile optimum öz nitelik alt kümeleri seçilmiş olur [39]. Bu yöntemin tek zayıf yönü çok fazla özniteliğe sahip algoritmalarda çok fazla işlem yükü gerektirmesidir. Bir başka öz nitelik alt küme seçim yöntemlerinden biri ise genetik algoritmalarıdır. Bu algoritma sayesinde öz nitelikler evrimleşme sürecini taklit ederek optimum öz nitelik alt kümelerini oluştururlar [40]. Sıkça kullanılan başka öz nitelik alt kümesi seçme yöntemlerinden bazıları ise Ardışıl İleri Seçme ve Ardışıl Geri seçme algoritmalarıdır. Bu algoritmalarda tamamen boş alt kümelerden ya da tamamen dolu alt kümelerinden birer birer öznitelikler eklenerek eksiltiyle adım adım uygun alt kümeler araştırılır. Bu Ardışıl İleri Seçme algoritmasının dezavantajı, eklenen herhangi bir öz niteliğin sonraki adımlarda kümelerden çıkartılamıyor olmasıdır [41].

#### **1.4.5.2.3. Temel Bileşen Analizi**

Temel bileşen analizi (TBA) çalışmalarına 1901 yılında Karl Pearson tarafından başlanmıştır [70]. TBA, biribiri ile ilişkili birçok değişkenin bulunduğu veri setinin boyutlarını, verinin özelliğinin mümkün olduğunca korunacak şekilde azaltılması işlemidir [71]. TBA işlemi sırasında elde edilen ilk değişkenlere kullanılan verinin temel bileşenleri

adı verilir. Elde edilen tüm değerlerden varyansı en büyük değişken ilk temel bileşendir. İlk temel bileşenden son temel bileşene doğru ise varyans değerleri sürekli olarak azalır. TBA'nın avantajları ise; az boyutlu uzaylarda daha etkin çalışma avantajı sağlaması, gürültüye karşı hassasiyetinin az olması, verinin boyutunun azaltılarak daha az bellek kullanılmasının sağlaması olarak sayılabilir [72].

TBA yöntemi kullanılarak veri boyutu azaltılırken veriye ait matrise bazı işlemler uygulanır. Eğer veri matrisinin  $V$ , denklem (5)'te gösterildiği gibi bir matristen oluştuğu varsayılırsa işlemler takip eden eşitliklerde olduğu gibi gerçekleşir.

$$V = \begin{bmatrix} v_1^1 & v_1^2 & \dots & \dots & \dots & v_1^M \\ v_2^1 & v_2^2 & \dots & \dots & \dots & v_2^M \\ \vdots & \vdots & \dots & \dots & \dots & \vdots \\ v_N^1 & v_N^2 & \dots & \dots & \dots & v_N^M \end{bmatrix} \quad (5)$$

Veriye ait vektörlerin ortalaması alınarak her bir vektörden çıkartılır. Oluşan yeni matris ise denklem (6)'daki gibi olur.

$$\bar{V} = \begin{bmatrix} v_1^1 - ort_1 & v_1^2 - ort_1 & \dots & \dots & \dots & v_1^M - ort_1 \\ v_2^1 - ort_2 & v_2^2 - ort_2 & \dots & \dots & \dots & v_2^M - ort_2 \\ \vdots & \vdots & \dots & \dots & \dots & \vdots \\ v_N^1 - ort_N & v_N^2 - ort_N & \dots & \dots & \dots & v_N^M - ort_N \end{bmatrix} \quad (6)$$

(6) denkeleminde  $ort$  ifadesi her bir satıra ait elemanların ortalamasını ifade etmektedir. Bir sonraki işlemde  $\bar{V}$  matrisinin kovaryans matrisi (7) denklemi kullanılarak hesaplanır. Oluşan kovaryans matrisi ise (8) denklemindeki gibi olur.

$$C = \bar{V}\bar{V}^T \quad (7)$$

$$C = \begin{bmatrix} (v_1^1 - ort)^2 & \dots & (v_1^M - ort)(v_1^1 - ort_N) \\ \vdots & \ddots & \vdots \\ (v_N^1 - ort_N)(v_1^M - ort_1) & \dots & (v_N^M - ort_N)^2 \end{bmatrix} \quad (8)$$

(8) denklemi ile elde edilen kovaryans matrisinde köşegen üzerinde bulunan katsayılar varyansı, geri kalan elemanlar ise kovaryans değerlerini gösterir. Varyans değerleri verinin ortalama içerisindeki dağılımını gösterirken, kovaryans değerleri ise değişkenlerin

birbirleriyle nasıl deęişim gösterdiğini ifade eder. Eđer deęişkenler arasında herhangi bir ilişki yoksa kovaryans deęeri sıfır olur.

TBA’da elde edilen kovaryans matrisinde özdeęer ve özvektörlerin ayrılmasında (9) denklemi kullanılır.

$$Cx = \lambda x \quad (9)$$

Denklem (9)’da  $C$   $N \times N$  boyutlu bir matrisi,  $\lambda$  herhangi bir skaleri,  $x$  ise sıfırdan farklı sütun vektörünü ifade etmektedir.

Elde edilen özdeęerler büyükten küçüğe doęru sıralandığında bunlara karşılık gelen özvektörler de sıralanır. Burada belirlenen sayıda özvektörün en iyi izdüşümünü gerçekleştirecek bir izdüşüm matrisi oluşur. Veriye ait örneklerin öz nitelikleri, özvektörlerin belirledięi uzayın üzerine izdüşümü alınarak TBA sonucunda elde edilen boyutu azaltılmış yeni matris elde edilir. Elde edilen yeni matris ise (10) denklemi ile gösterilmiştir.

$$y^i = W^T v^i, i = 1, 2, \dots, M \quad (10)$$

(10) denkleminde  $y$  ile ifade edilen deęer TBA sonucu oluşan boyutu azalmış yeni deęerleri gösterir.  $W$  deęeri ise oluşturulan en iyi izdüşüm matrisidir.  $v$  deęeri ise kullanılan matrisin her bir elemanını ifade etmektedir [73].

### 1.4.5.3. Normalizasyon

Normalizasyon işlemi, verilerin tekrarını engellemek ve verileri kendi arasında ağırlıklandırılarak kolayca erişime sunma işlemidir [42]. Normalizasyonlar Yerel ve Global normalizasyonlar olmak üzere iki çeşittir.

Lokal normalizasyonda veri içerisindeki sadece bir öz niteliğe bu normalizasyon işlemi yapılır. Bunun sebebi hem sensör kaymalarından doğan sorunları minimize etmek hem de koku yoğunluęundaki deęişikliğe baęlı olarak ortaya çıkan deęişkenlikleri azaltmaktır.

Global normalizasyonda veri içerisindeki tüm özniteliklere bu normalizasyon türü uygulanarak işlem yapılır. Bu normalizasyonun yapılmasının sebebi, farklı büyüklüklerdeki öznitelikleri birbiri ile kıyaslayabilmek ve de değerlendirebilmektir.

Normalize edilmiş tüm özniteliklerin 0 ile 1 arasında olması için literatürde çoğunlukla kullanılan üç yöntem vardır. Bunlar; vektör, doğrusal ve monoton olmayan normalizasyon yöntemleridir [70].

$$r_{i,j} = \frac{x_{i,j}}{\sqrt{\sum_{i=1}^m x_{i,j}^2}}, i = 1,2,3 \dots, m; j = 1,2,3 \dots, n. \quad (11)$$

$$r_{i,j} = \frac{x_{i,j}}{\sum_{i=1}^m x_{i,j}^2}, i = 1,2,3 \dots, m; j = 1,2,3 \dots, n. \quad (12)$$

$$e^{(-z^2/2)}, z = \frac{x_{i,j} - x_j^0}{s_j} \quad (13)$$

(11) ifadesi vektör normalizasyonunu, (12) ifadesi doğrusal normalizasyonu, (13) ifadesi ise monoton olmayan normalizasyonu ifade eder. İfadelerde yer alan  $x_{ij}$  matristeki her bir elemanı,  $r_{ij}$  normalize edilmiş matrisi,  $x_j^0$  ifadesi  $j$  ölçütüne ilişkin en uygun değeri ve  $s_j$  ise  $j$  değerine ilişkin standart sapmayı göstermektedir.

#### 1.4.6. Örüntü Tanıma Birimi

Elektronik burun ile koku algılama sistemlerinde en önemli birimlerden birisi de örüntü tanıma birimidir. Sağlıklı sensör verilerinin işlenmesi bu kısımda yapılmaktadır. Sensörlerden alınan kokuya ait elektriksel işaret sayısal işarete dönüştürüldükten sonra bilgisayarda işlenerek anlamlandırılmaya dolayısıyla da sınıflandırılmaya çalışılır.

Örüntü tanıma biriminin oluşturulmasındaki ana sebep insanlardaki tecrübelerden ortaya çıkmıştır. İnsanlar akılları sayesinde çevreyi algılayarak ortak veya zıt yönlerini analiz ederler. Bu sayede her yeni olay veya durum karşısında, önceki durumlardan ya da benzerliği bulunan ortak noktalardan yola çıkarak yeni koşulların değerlendirmesini yapar. Buna benzer şekilde makine öğrenmesi de bu noktayı temel almaktadır. Oluşan her yeni

durumda daha önceki durumları analiz ederek, yeni sonuçların ortaya çıkarmasını sağlamaktadır [43].

Örüntü tanıma teknikleri sayesinde pek çok alanda başarılarla imza atılmıştır. Bu alanlar; tıp, askeri, kimyasal, biyomedikal ve mühendislik gibi önemli alanlardır. Bu alanlarda; sesin tanınmasında, radarlarda hedeflerin sınıflandırılarak hangi nesneye ait olduğunun belirlenmesinde, biyomedikal işaretlerin analizi yapılarak canlı sağlığını koruyucu önlemler alınabilmesinde, nitelik tahminleri yapılması gibi alanlarda kullanılmaktadır.

Kokular incelendiğinde her kokunun kendine has bir özelliği, aynı zamanda kendine has olmayan ortak olarak da birçok özelliği vardır. Kokuların kendilerine has özelliği sayesinde canlılar ve elektronik burunlar tüm kokuları ayırt ederler. Bu ayırt etme sırasında kokuya ait bilgiler tutularak koku veri tabanı oluşturulur [44]. Oluşturulan bu veri tabanı sayesinde insanlar kokuları yaklaşık olarak tahmin ederken elektronik burun sistemleri ise makine öğrenmesi sayesinde kesin tahminlerde bulunabilirler. Tüm bu tahmin sistemlerinin sistem tarafından otomatik olarak algılanabilmesi için genellikle istatistiksel, nöromorfik ya da istatistiksel algoritmalar kullanılmaktadır [45].

Sensörlerden alınan bilgiler sırasıyla; işaret koşullama, işaret ön işleme ve örüntü tanıma işlemlerinden geçerek sınıflara ayrılır. Sınıflandırmanın amacı, herhangi bir nesneye ait kokunun en az hata ile kendine en uygun kümeye ait olduğunun belirlenmesidir. İşlemlerdeki en önemli kısımlar özniteliklerin belirlenmesi ve uygun sınıflandırma algoritmasının seçilmesidir.

Hemen hemen bunların dışında kalan tüm durumlarda ortak bir ilerleme söz konusu iken, bu iki işlemde pek çok olasılık ve kombinasyon vardır. Bu durumda bulunacak en optimum sonuçlar, verilerin en iyi analizi sayesinde ortaya çıkar.

#### **1.4.6.1. Destek Vektör Makineleri**

Destek Vektör Makineleri, istatistiksel olarak öğrenmeye dayalı sınıflandırma algoritmalarından biridir. Destek vektör makineleri ilk ortaya çıktığı dönemde sadece doğrusal iki sınıfın birbirinden ayrılması için kullanılırken, zamanla daha çok sınıflı verilerin birbirinden ayrabilmesi için geliştirilmiştir.

Destek vektör makineleri iki sınıfı birbirinden ayırırken en uygun karar fonksiyonunu belirler. Bu karar fonksiyonuna ise en uygun hiper-düzlem tanımlanarak verideki sınıfların birbirinden ayrılması sağlanır [46].

İki sınıfa ait verilerden oluşan bir veri kümesinde ilk olarak her bir sınıfı temsil eden  $\{-1, +1\}$  şeklinde sınıf etiketleri oluşturulur. Sınıflandırma işlemi için veri kümesi; eğitim ve test verisi olarak iki kısma ayrılır. Eğitim verileri ile sistem eğitilirken, test verileri ile de sistemin ne kadar doğru öğrenebildiği test edilir. Eğitim esnasında sistemin eğitim verilerinden fonksiyon üretilmesi için faydalanılır. Üretilen fonksiyon sayesinde uygun bir hiper-düzlem oluşturularak test verileri ile sistemin ne kadar iyi sınıflandırabildiği test edilir. Hiper-düzlem yalnızca bir tane değil birden fazla da olabilir. Ancak destek vektör makinelerinde istenen, iki sınıfa ait noktalar arasında mesafeyi maksimuma çıkaran hiper-düzlemi bulmaktır. Burada bulunan hiper-düzlem en optimum hiper-düzlem olur. Sınır genişliğinin alındığı noktalar ise bu hiper-düzlemin destek vektörleri olur [48].

Doğrusal olarak ayrılabilen iki sınıflı bir veride eğitim verisinin  $n$  tane örnekten oluşan  $\{a_j, b_j\}$  ve  $j=1,2,3\dots n$  olarak kabul edilirse optimum hiper-düzlemi oluşturacak eşitsizlik (14) ve (9)'da ki eşitsizliklerdeki gibi olacaktır.

$$w \cdot a_j + k \geq +1 \quad \forall b = -1 \quad (14)$$


$$w \cdot a_j + k \leq -1 \quad \forall b = +1 \quad (15)$$

Bu eşitsizliklerde  $a \in \mathbb{R}^N$  'de  $N$ -boyutlu veriye ait uzayı ifade eder.  $b \in \{0, 1\}$  olarak veriye ait sınıf etiketlerini belirtir.  $w$  ağırlık vektörünü  $k$  ise eğilim değerini vermektedir. Oluşturulan bu hiper-düzlemin ise destek vektörleri denklem (16)'daki gibi olur.

$$w \cdot a_j + k = \pm 1 \quad (16)$$

Optimum olarak seçilen hiper-düzlemde sınır değerlerinin maksimum olabilmesi için  $w$  değerinin en minimum değerinde olmasına özen gösterilir. Bu durumun çözümü için (17) ile verilen denklem kullanılır. Şekil 8'de optimum hiper düzlemle ayrılmış sınıflar gösterilmektedir. Sınır değerlerinin belirlenmesinde ise destek vektörlerinden yararlanılmıştır.





Şekil 8. Optimum hiper-düzlem ve destek vektörleri [47].

$$\min \left[ \frac{1}{2} \cdot w^2 \right] \quad (17)$$

Ortaya çıkan sınırlamalar ise (18) ifadesindeki gibi olur.

$$b_j(w \cdot a_j + k) - 1 \geq 0 \text{ ve } b_j \in \{-1, +1\} \quad (18)$$

Bu ifade ise Langrage denklemleri yardımıyla çözülmüşse;


$$L(w, k, x) = \frac{1}{2} \cdot w^2 - \sum_{j=1}^n x_j b_j (w \cdot a_j + k) + \sum_{j=1}^n x_j \quad (19)$$

(19) eşitliği elde edilir. Bu eşitliğe bağlı karar fonksiyonu yazılırsa;

$$f(x) = \text{sign} \left( \sum_{j=1}^n \lambda_j b_j (a \cdot a_j) + b \right) \quad (20)$$

(20) fonksiyonu elde edilir [48].

Doğrusal olarak birbirinden ayrılabilen sınıflar olduğu gibi doğrusal olarak birbirinden ayrılamayan sınıflar da vardır. Bu durum farklı sınıflara ait bazı verilerin optimum hiper-düzlemin diğer tarafında kalmasından dolayıdır. Bu problemin çözümü için pozitif yapay bir değişken olarak  $\xi_j$  tanımlanır. Yanlış sınıflandırmadan dolayı meydana gelen sınıflandırma hataları ve optimum-hiper düzlem sınırının maksimum hale getirilmesi için sadece pozitif değerler alan, sıfırdan farklı olarak  $C$  ile gösterilen bir düzenleme parametresi kullanılabilir. Şekil 9'da doğrusal olarak ayrılamayan verilere ait sınıflar gösterilmiştir. Sınır değerleri belirlenirken farklı sınıflara ait elemanlar hiper düzlemin farklı tarafında kalmıştır.



Şekil 9. Doğrusal olarak ayrılamayan veriler ve hiper-düzlem [47].

Yapay değişken ve düzenleme parametresi ile doğrusal olarak ayrılamayan optimizasyon problemi yeniden oluşturulursa:

$$\min \left[ \frac{w^2}{2} + C \cdot \sum_{j=1}^n \xi_j \right] \quad (21)$$


(21) ifadesi oluşur. Buna bağlı oluşan sınırlar ise:

$$b_j(w \cdot \varphi(a_i) + k) - 1 \geq 1 - \xi_j, \quad \xi_j \geq 0 \text{ ve } j = 1, \dots, n \quad (22)$$

(22)'de ifade edilen şekli ile ortaya çıkar. (21) ve (22) ifadelerinde elde edilen optimizasyon problemlerinde çözüm için veriler bir üst uzay olan özellik uzayına taşınarak görüntülenir. Bu uzayda çizilecek yeni optimum hiper-düzlem ile de sınıflara ayrılması sağlanmış olur. Çünkü bu uzayda verilerin doğrusal olarak ayrılması mümkün olacaktır.

Doğrusal olarak destek vektörleri ile ayrılamayan verileri bir üst uzaya taşıma işlemi kernel fonksiyonu sayesinde olur. Kernel fonksiyonu (23) eşitliği ile ifade edilmektedir. Şekil 10'da kernel fonksiyonları ile oluşturulan özellik uzayının girdi uzayının aksine sınıfları hiper düzlem ile ayırabildiği gösterilmektedir.

$$K(a_i, a_j) = \varphi(a_i) \cdot \varphi(a_j) \quad (23)$$



Şekil 10. Kernel fonksiyonu ile oluşan girdi ve özellik uzayı [47].

Kernel fonksiyonunu kullanarak ayrılamayan iki sınıflı bir problemin çözümü için oluşturulacak fonksiyon (24)'de belirtilen ifadedeki gibi olur.


$$f(x) = \text{sign} \left( \sum_i^n x_i b_i \cdot \varphi(a_i) + b \right) \quad (24)$$

Çalışılarda sınıflandırma için kullanılan pek çok kernel fonksiyonu vardır. Bunlardan en çok kullanılanları ise; Pearson VII fonksiyonu, radyal tabanlı fonksiyon ve normalize edilmiş kernel polinomlarıdır.

### 1.4.6.2. Doğrusal Ayırma Analizi

Doğrusal ayırma analizi 1936 yılında ilk olarak R. A. Fischer tarafından geliştirilmiştir. Doğrusal ayırma analizi, nesnelere ait verinin sınıf bilgisi kullanılarak, sınıflarına göre ayrışabileceği uzayda yer alan lineer katsayıları bulmayı sağlayan boyut indirgeme yöntemidir. Bu yöntem sayesinde, üzerinde ölçüm yapılan bir nesnenin hangi sınıfa ait olduğu istatistiksel yöntemler kullanılarak bulunmaktadır. [49].

Doğrusal ayırma analizi, nesnelere ait verilerin birbirinden en iyi ayrılabilmesi için bir alt uzaydaki yansımalarının en optimumunun elde edilmesi üzerine kullanılan bir yöntemdir. Bu yöntem ile birçok zorlu matematiksel problemi karmaşık metotlarla çözmek yerine daha basit modeller üreterek çözer. Şekil 11’de Doğrusal ayırma analizinin 3 boyuttan 2 boyuta düşürülmesi ile oluşacak alt uzayların yansıma örnekleri verilmiştir.



Şekil 11. 3-boyutlu verilerin alt uzaylardaki yansımaları [50].

Fischer’in farklı nesnelere ait sınıfları en iyi şekilde ayırabilecek bir amaç fonksiyonu tanımlamıştır. Bu amaç fonksiyonuna ait eşitlikler ise aşağıda ifade edilen şekildedir.

$$Z = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_d x_d \quad (25)$$

$$S(\beta) = \frac{\beta^T \mu_1 - \beta^T \mu_2}{\beta^T \cdot C \cdot \beta} \quad (26)$$

$$S(\beta) = \frac{\bar{z}_1 - \bar{z}_2}{Z \text{ gruplarının varyansı}} \quad (27)$$

(25) denklemi Fischer'in amaç fonksiyonudur. Verilen bu amaç fonksiyonu aşağıda verilen eşitlikler yardımıyla maksimize edilerek problemin çözümü için lineer katsayılar tahmin edilebilir.

$$\beta = c^{-1}(\mu_1 - \mu_2) \quad (28)$$

$$C = \frac{1}{n_1 + n_2} (n_1 C_1 + n_2 C_2) \quad (29)$$

(28)'de verilen eşitlikte model katsayılarına ait eşitlik verilmiştir. (29)'de ise birleştirilmiş kovaryans matrisine ait eşitlik verilmiştir.  $\beta$  ifadesi lineer model katsayılarını,  $C_1$  ve  $C_2$  kovaryans matrisleri,  $\mu_1, \mu_2$  ise ortalama vektörleri ifade etmektedir.

İki grup arasındaki en iyi ayrımı belirleme yolu, Mahalonobis mesafesini hesaplamaktır. Hesaplanan Mahalonobis mesafesinin 3'ten küçük olduğu durumlarda yanlış sınıflandırma olasılığı azalmaktadır. İki grup arasındaki Mahalonobis mesafesi (30) ifadesi ile bulunur.

$$\Delta^2 = \beta^T (\mu_1 - \mu_2) \quad (30)$$

Eğer son olarak (31) ile ifade edilen koşul sağlanırsa herhangi bir nesneye ait yeni gelen veriler sınıflandırılabilir.

$$\beta^T = \left( x - \left( \frac{\mu_1 + \mu_2}{2} \right) \right) > \log \frac{p(c_1)}{p(c_2)} \quad (31)$$

(31) ifadesinde,  $\beta^T$  katsayı vektörünü,  $x$  veriye ait vektörü,  $(\mu_1 + \mu_2)/2$  ortalama vektörü ve logaritması alınan ifade de sınıf olasılıklarını göstermektedir [51].

Doğrusal ayırma analizi ile karesel ayırma analizi karşılaştırıldığında, doğrusal ayırma analizinin çok daha az esnek bir sınıflandırma özelliğine sahip olduğu görülür. Dolayısıyla önemli ölçüde daha düşük varyansa sahiptir. Bununla birlikte, doğrusal ayırma analizinde varyansın değeri büyükse, yüksek sapmaya uğrar. Genellikle az sayıda eğitim verisi içeren

veri kümelerinde doğrusal ayırma analizi, karesel ayırma analizinden daha iyi sonuç verir. Bu nedenle varyansı azaltmak önemlidir.

### 1.4.6.3. k-En Yakın Komşu

k-En yakın komşu algoritması, T. M. Cover ve P. E. Hart tarafından geliştirilmiş bir sınıflandırma algoritmasıdır. Bu algoritma bilinen ve kullanımı en eskiye dayanan örüntü tanıma algoritmalarından biridir. Bu algoritmanın kullanılması kolay ve öğrenilmesi ise basittir [52]. Örüntü tanımının yanı sıra veri madenciliği, bilişsel psikoloji, yapayzeka, istatistik, biyoinformatik ve tıp gibi pek çok alanda kullanılmaktadır [53].

k-En yakın komşu algoritmasının eğitime ihtiyaç duymaması, analitik takibinin yapılabilmesi, gürültü barındıran eğitim verilerine karşı dirençli olması gibi pek çok avantajı vardır [54]. Ancak bu avantajların yanı sıra birçok da dezavantajı vardır. Bunlar; yüksek belleğe ihtiyaç duyması, veri boyutu fazla olan işlemlerde buna paralel olarak işlem süresinin artması, performansının k-en yakın komşu sayısı ile birlikte değişiklik göstermesi ve özniteliklere bağlı olarak değişkenliklerden etkilenmesidir [55].


k-En yakın komşu algoritmasında sınıfı belirlenmek için etiketi belirlenmiş örnek veriler ile sistemi test edecek veriler arasındaki mesafeler hesaplanır. Sistemi test etmek için kullanılan veri en çok hangi sınıfa yakınsa o sınıfa ait olduğu kabul edilir. Küçük boyutlu veri kümelerinde işlem süresi kısarken, büyük veri kümelerinde tek tek mesafelerin her bir örnek için ölçülmesi zaman alacağından işlem süresi artmaktadır. İşlem süresini kısaltmak için etiketleri bilinen veri kümelerine ait özniteliklerden fazlalık olan kısımlar temel bileşen analizi gibi boyut azaltma yöntemleri ile çıkarılabilir [56].

k-En yakın komşu algoritması parametrik olmayan bir algoritma türüdür. En az iki sınıfa ait veriler sınıflandırılırken belirli mesafe ölçüm yöntemlerine bağlı olarak, komşu sayısına bağlı olarak ya da ağırlıklandırma ile yeni verilere ait sınıflandırma tahmininde bulunur. k-En yakın komşu algoritmasında  $k$  ifadesi hangi sınıfa ait olduğu bilinmeyen verinin en yakınındaki komşu sayısını göstermektedir.

k-En yakın komşu algoritmasında uzaklık ölçüm yöntemleri olarak Öklid, Manhattan, Chebyshev, Minkowski ve Dilca uzaklığı kullanılmaktadır.

Öklid uzaklığı k-En yakın komşu algoritmasında mesafe ölçümü için en çok seçilen yöntemlerden biridir. Öklid uzaklığı, her iki nokta arasındaki en kısa mesafeyi ifade eden doğrusal uzaklıktır. Herhangi bir  $A$  ve  $B$  noktası arasındaki mesafe ölçümü,  $A=(x_1, x_2, \dots, x_n)$

ve  $B=(y_1, y_2, \dots, y_n)$  noktaları olmak üzere (32) denklemine göre hesaplanır. Şekil 12’de en yakın komşuluklarına göre sınıfların nasıl seçildiği gösterilmiştir.



Şekil 12. k-En yakın komşu algoritması k seçimi [57].

$$|A - B| = \left( \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \right) \quad (32)$$

Bir başka k-En yakın komşu algoritmasında kullanılan uzaklık ölçüm yöntemlerinden biri de Manhattan uzaklığı yöntemidir. Bu yöntemde  $A$  ve  $B$  gibi farklı iki nokta arasındaki koordinatları arasındaki farkların toplamıdır.  $A=(x_1, x_2, \dots, x_n)$  ve  $B=(y_1, y_2, \dots, y_n)$  noktaları olmak üzere Manhattan uzaklığı (33) denklemine göre hesaplanır:

$$|A - B| = \left( \sum_{i=1}^n |x_i - y_i| \right) \quad (33)$$

Minkowski uzaklığı, Öklid ve Manhattan uzaklığı gibi uzaklık ölçümlerinin genelleştirmiş halidir.  $A=(x_1, x_2, \dots, x_n)$  ve  $B=(y_1, y_2, \dots, y_n)$  noktaları arasındaki mesafe ölçümü ise (34) denklemine göre şu şekilde hesaplanır:

$$|A - B| = \left( \sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (34)$$

Burada  $p$  ile ifade edilen değer Öklid için  $p=2$ , Manhattan için  $p=1$  olduğu durumlarda kullanılabilir. Chebyshev uzaklığı içinse  $n \rightarrow \infty$  olduğu durumlarda kullanılır.

Chebyshev uzaklığı, sonsuz boyuta yaklaşan iki noktanın koordinatları farklarının mutlak değerlerinin maksimumu şeklinde tanımlanır.  $A=(x_1, x_2, \dots, x_n)$  ve  $B=(y_1, y_2, \dots, y_n)$  noktaları arasındaki mesafe ölçümü ise (35) denklemine göre şu şekilde hesaplanır:

$$|A - B| = \lim_{p \rightarrow \infty} \left( \sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} = \max_{i=1}^n |x_i - y_i| \quad (35)$$

Dilca (Distance Learning in Categorical Attribute) uzaklığı kategorilere ayrılmış öznitelikler arasındaki uzaklığı ölçerek K-En yakın komşu algoritmasında kullanılır. Dilca uzaklığı ölçümleri iki adımdan oluşur. Birinci adımda simetrik belirsizlik katsayısı yöntemi ile öznitelik seçimi yapılır. Burada bilgi kazancı genellikle yüksek değerlikli özniteliklerin olduğu kısımda fazladır. Simetrik belirsizlik katsayısı, K ve L gibi özniteliklerin bilgi kazancının entropi değerlerine bölünmesi ile elde edilir. Bu denklem (36) ile ifade edilmiştir.

$$SU = 2. \left[ \frac{IG}{H(L) + H(K)} \right] \quad (36)$$

Burada  $SU$  simetrik belirsizlik katsayısını,  $IG$  bilgi kazancını,  $H(K)$ ,  $H(L)$  ise K ve L'ye ait entropi değerlerini göstermektedir.

İkinci adımda koşullu olasılık ve Öklid uzaklığına bağlı olarak uzaklıklar ölçülmektedir. Bu uzaklık ölçümleri (37) ile ifade edilen eşitlikte verilmektedir.

$$d_i(K, L) = \sqrt{\frac{\sum_{K \in \text{bağlam}(a_i)} \sum_{K_k \in K} \left( P\left(\frac{K}{K_k}\right) - P(L/K_k) \right)^2}{\sum_{K \in \text{bağlam}(a_i)} |K|}}, \quad 0 \leq d_i(K, L) \leq 1 \quad (37)$$



Burada,  $K$  ve  $L$  incelenen özniteliğe ait değerlerdir. Her bir  $L$  bağlam özniteliği için  $K$  özniteliklerine bağlı koşullu olasılıklar hesaplanarak Öklid uzaklığı bulunmaktadır. Bağlam özellikleri ise simetrik belirsizlik katsayısı yardımıyla yapılmaktadır [58].


#### 1.4.6.4. Karar Ağaçları

Karar ağaçları son zamanlarda ortaya çıkan, sıkça kullanılan örüntü tanıma ve sınıflandırma algoritmalarından biridir. Çok tercih edilmesindeki sebep, kolay ve anlaşılabilir yapıda olmasıdır. Karar ağaçlarındaki yapılar aşamalı ve ardışık bir sırada ilerler. Bu nedenle karmaşık görünen problemler aşamalı hale getirilerek basitleştirilebilir [59].

Karar ağaçlarında yapılar yaprak, dal ve düğüm olmak üzere üç kısımdan meydana gelir. Her bir öznitelik, ağaçta bulunan düğümlerle temsil edilir. Karar ağacı kurulurken en tepedeki düğüm kökü ifade eder. Kök ile yapraklar arasında kalan kısımlar ise dalları ifade eder [60].

Karar ağaçlarında temel amaç veriye ait özniteliklere uygun sorular sorarak elde edilen cevaplara göre en kısa yoldan sonuca ulaşılmasıdır. Bu işlem kökten başlar, ta ki sınıflar ayrılıncaya ya da bir başka deyişle yapraklara ulaşıncaya kadar devam eder.

Şekil 13'te görülen karar ağacı örnek modelinde kökten yapraklara giden sadece bir yol ya da tek bir karar kuralı vardır. Burada ifade edilen "A, B, C" ifadeleri sınıfları göstermektedir.



Şekil 13. Karar ağacı yapısı [61].

Karar ağaçları tek değişkenli ve çok değişkenli olarak iki kısma ayrılabilir. Tek değişkenli karar ağacında bir iç düğümde tek bir öznitelik test edilerek veri iki ya da daha fazla sınıfa ayrılarak bir sonraki aşamaya geçilir. Bu işlem tekrarlı olarak yaprak düğümüne ulaşıncaya kadar devam eder. Tek değişkenli karar ağaçlarında karar sınırları eğitim verisi içerisinde deneysel olarak bulunur. Eğer veri sürekli bir veri ise eğitim verisi içerisindeki her bir iç düğüm  $x_i$ 'nin veri uzayında bir özelliği gösterdiği ve  $c$ 'nin gözlenen aralıkta bir eşik değeri olduğu varsayılarak  $x_i > c$  olarak sınıması yapılabilir. Eşik değeri olarak belirlenen  $c$  ile farklılıklar maksimum hale getirilirken, iniş düğümlerindeki benzerlikler ise minimum hale getirilir.

Karar ağaçlarında yapılan dallanma belirli kriterler ve yöntemlere göre yapılır. Literatür incelendiğinde bu yönde yapılmış pek çok çalışma vardır. Çoğunlukla kullanılan yöntemler: Gini indeksi, Towing kuralı, bilgi kazancı, bilgi kazanç oranı, Ki-Kare olasılığıdır.

En çok kullanılan yöntem olan bilgi kazancı ve bilgi kazanç oranı, dallanmanın yapılabilmesi için entropi kurallarını kullanarak dallanmanın hangi kurala göre yapılacağını belirlemek için kullanılır.

Bilgi edinme için ayrıca ID3 ve daha da geliştirilmiş olarak C4.5 algoritması kullanılmaktadır [62].  $S_1, S_2, \dots, S_n$  şeklinde sınıflardan oluşan ve  $T$ 'nin de sınıf değerlerini gösterdiği bir veri setine ait olasılık:  $P_i = (S_i | T)$  şeklinde olur. Entropisi ise,

$$Entropi(T) = - \sum_{i=1}^n P_i \log_2(P_i) \quad (38)$$

ile hesaplanır. Veri setine ait öznitelikler  $B$  ile ifade edilirse, sınıf değerleri özniteliklere göre  $T_1, T_2 \dots T_n$  şeklinde alt kümelere ayrılır. Buradan elde edilecek kazanç ise,

$$Kazanç(B, T) = Entropi(T) - \sum_{i=1}^n \frac{T_i}{T} \cdot Entropi(T_i) \quad (39)$$

eşitliği ile hesaplanır.  $T$ 'ye ait  $B$  özniteliklerinin değerinin belirlenmesinde bölümlenme bilgisi kullanılır.

$$\text{Bölümleme Bilgisi } (B) = - \sum_{i=1}^n \frac{T_i}{T} \cdot \log_2 \left( \left| \frac{T_i}{T} \right| \right) \quad (40)$$

$$\text{Kazanç Oranı} = \frac{\text{Kazanç } (B, T)}{\text{Bölünme Bilgisi } (B)} \quad (41)$$

Bölümleme bilgisi ve kazanç oranı (40) ve (41) eşitliklerindeki gibi hesaplanır. Kazanç oranının bulunması ile ayırma işleminde elde edilecek bilgi ifade edilir. Bu sayede karar ağacının her düğümünde kazanç oranı en yüksek olacak şekilde  $T$  kümesi ayrıştırılabilir. Bu işlem yapraklarda tek sınıf kalana kadar devam eder.

Karar ağacında yapılan bir diğer işlem ise budama işlemidir. Karar ağaçları kullanılırken pek çok işe yarayan ya da yaramayan dallanma yaparak yapraklara doğru ilerler. Bu sırada ortaya çıkan karmaşa, işlem yükünü artırırken aynı zamanda da karmaşıklığı artırır. Bunu engellemek için karar ağacında budama yapılır.

Yapılan budamanın sonucunda sınıflandırma başarısında bir etkilenme olmaz. Bu nedenle kullanımında herhangi bir sakınca yoktur. Karar ağaçlarında budama için iki yöntem sıklıkla kullanılmaktadır. Bunlardan birincisi karar ağacı oluşturulması esnasında yapılan budama işlemi iken, ikincisi ise ağaç yapısı oluştuktan sonra gereksiz ve tekrarlı kısımların atıldığı son budama işlemidir. C4.5 algoritmasında kullanılan ön budama işlemi ile bilgi kazancı, daha az işlem yükü ve veri setini ayrıştıracak en iyi yolu araştırması yönüyle önemli avantaja sahiptir.

Karar ağaçlarında dallanma devam ederken geline en son nokta yaprağı oluşturur. Geline son noktanın yaprak olarak anlaşılması ise belirli bir eşik seviyesinin altında bölünme yapılamaması ile bulunur [63].

#### 1.4.6.5. Sınıflandırıcı Toplulukları Yöntemi

Sınıflandırıcı toplulukları yöntemi makine öğrenme algoritmalarından biridir. Bu algoritma sayesinde güçsüz pek çok algoritma birleşerek daha güçlü algoritmalar bütünü oluşturabilir. Bir verinin sadece en yüksek başarı oranını veren bir algoritma yerine birçok algoritmanın birlikte oluşturacağı bir topluluk ile verilerin sınıflandırılmasının yapılması esasına dayanır. Her bir sınıflandırma algoritmasının yaptığı sınıflandırma ile vereceği oy

ile oylama işlemi yapılır. Bu oylama işlemi sınıflandırmanın hangi yönlü yapılacağı seçilmiş olur.

Sınıflandırıcı toplulukları yöntemi ile tek bir sınıflandırıcının sebep olduğu üç problem ortadan kaldırılmış olur. Bu problemler sıklıkla karşılaşılan: istatistiksel problemler, ölçüm problemleri ve temsil problemleridir.

İstatistiksel problemler çok fazla eğitim verisinin olduğu durumlarda artmaktadır. Bu gibi durumlarda, farklı birkaç sınıflandırıcı aynı sınıflandırma başarısının verebilmektedir. Öğrenme algoritması ise bu eğitim verisinin çıkışlarından herhangi birini seçer. Bu da seçilen sınıflandırıcının doğru öznitelik verilerinin seçiminde yanlış karar verme riskini ortaya çıkarır. Bu durumlarda iyi ve eşit sınıflandırıcılar arasında yapılacak bir oylama ile risk azaltılabilir.

Ölçüm problemleri, öğrenme algoritmasının en iyi sınıflandırıcıyı bulmayı garanti edemediği durumlarda artar. Örneğin, yapay sinir ağları ve karar ağaçları algoritmasında, en uygun eğitim verilerini kullanmak için sezgisel yöntemler kullanılmaktadır.

Bu sezgisel yöntemler (gradient descent gibi) yerel minimuma sıkışabilir ve bu nedenle en uygun yöntemi bulamazlar. Bu gibi istatistiksel yöntemlerde birkaç farklı minimum noktasının birkaç farklı ağırlık kombinasyonu yanlış minimum nokta bulma riskini azaltır.

Son olarak temsil problemleri ise sınıflandırıcıların hiçbir uzayda iyi yaklaşım elde edemediği ifadelerin doğru bir fonksiyon ile ifade edilemediği durumlarda artış gösterir. Bu gibi durumlarda, uzayın genişletilmesi ile birlikte ağırlıkların toplamı bu veriyi en iyi şekilde temsil edebilir. Böylece ağırlıklar ile yapılacak oylamada en iyi öğrenme algoritması ve en iyi yaklaşım fonksiyonu belirlenmiş olur [64].

Herhangi bir algoritma ile sınıflandırması yapılan bir veride, başarılı ve başarısız sınıflandırılan iki kısım veri oluşur. Bu iki kısım veriden başarısız olarak sınıflandırılan kısmı, bir başka algoritma türü ile başarılı olarak sınıflandırabiliyorsa bu iki algoritmanın birlikte kullanılması ile sınıflandırmaya ait başarı yüzdesi artırılabilir. Sınıflandırıcı toplulukları yönteminde; hızlandırılmış ağaç, torbalanmış ağaç, alt uzay ayrımı ve alt uzay en yakın komşu uygulamaları kullanılmaktadır [65].

Hızlandırma algoritması, bir sürecin yinelemeli olarak iyileştirilmesini hedefleyen bir algoritmadır. Bu algortmada sınıflandırılması güç olan verilere daha çok odaklanılır. Hızlandırma algoritmasında her bir veriye ağırlık değeri atanarak işlem yapılır. Bu ağırlık değerleri, algoritmanın doğru sınıflandırılması esası ile sürece devam eder. Bu süreç

boyunca doğru sınıflandırılan verilerin ağırlık değerleri düşürülürken, yanlış sınıflandırılan verilerin ağırlık değerleri yükseltilir. Bu sayede yanlış sınıflandırılan veri sürekli olarak yinelenerek doğru sınıflandırılması sağlandığı için başarı oranının yükselmesi sağlanır [66].

Torbalama algoritması, birçok sınıflandırıcıya ait sınıflandırma işlemi ile sınıflandırma başarısının yükselmesini hedefleyen bir algoritmadır. Bu algoritma ile eğitim verisinin farklı kısımları ile eğitilen sınıflandırıcılar bir araya getirilir. Her bir sınıflandırıcının kullandığı veri seti ise rastgele olarak dağıtılmıştır. Bunun sebebi ise etkin sonuçlar alabilmektir. Son durumda sınıflandırıcılardan çıkan eğitim sonuçlarına göre oylama yöntemi ya da ağırlık oylaması yöntemleri ile doğru sınıflandırılmaya çalışılır [67].

Rastgele alt uzay algoritması ile pek çok sınıflandırıcı kullanılarak sınıflandırma işlemi yapılır. Rastgele alt uzay algoritmasında diğer algoritmalarından farklı olarak, eğitim setinin veri uzayı kullanılmaz. Bunun yerine özniteliklere ait uzay kullanılır. Özniteliklere ait alt uzay farklılaştırılarak sınıflandırıcıların sınıflandırma tahmini yapması beklenir. Özniteliklere ait tüm alt uzaylar aynı boyutlu olarak oluşur.

Sınıflandırıcılara ait algoritmaların bu alt uzaylar üzerinden eğitilmesi ile eğitim sonuçlarına ulaşılır. Bu eğitim sonuçları da oylama yöntemi ile en başarılı sonuç ortaya çıkmış olur. Rastgele alt uzay algoritmasının avantajı ise alt uzaylarda işlem yaparak sınıflandırıcıların küçük alt problemler üzerinde çalışmasını sağlar [68].

### 1.5. K-Katlı Çapraz Doğrulama ve Başarı Ölçümü

K-Katlı çapraz doğrulama yöntemi, üzerinde çalışılan veri üzerinde doğru sınıflandırmanın hangi oranda doğru yapıldığını belirleyen bir yöntemdir. Bu yöntem ile eğitim ve test verileri sürekli olarak değiştiği için bulunana başarı oranlarının güvenilirliği daha fazladır [19].

K-Katlı çapraz doğrulama yönteminde öncelikle sistemi eğitecek ve test edecek verilerin hangi oranlarda ayrılacağını belirlenmesi ile yonteme başlanır. Verinin büyüklüğüne bağlı olarak  $K$  değeri 2, 5 veya 10 olarak seçilebilir. Genellikle literatürde  $K=10$  olarak seçilmiştir [19]. Seçilen bu  $K$  değeri verinin kaç parçaya bölüneceğini ifade etmektedir. Veri seti  $K$  adet eş parçaya bölünür. Bu eş parçalardan 1 tanesi sistemi test etmek için kullanılırken geri kalan eş parçalar ise sistemin eğitiminde kullanılır. Bu işlem  $K$  değeri sayısınca sıra ile tekrarlanır. Daha sonra ise tüm tekrarlarla elde edilen test sınavındaki başarı oranlarının ortalaması alınarak sonuca yansıtılır.

Yapılan bu tez çalışmasında sınıflandırma başarısını belirtmek için  $K=10$  olarak seçilmiştir.

Sınıflandırmadaki başarı oranını belirlemek için K-katlı çapraz doğrulama işleminde (42) ile ifade edilen denklemler kullanılmaktadır.

$$SD = \frac{DSVS}{TVS}, OSD = \frac{\sum_{i=1}^K SD_i}{k} \quad (42)$$

(42) denklemlerinde  $SD$  sınıflandırma başarısının,  $DSVS$  doğru sınıflandırılan veri sayısını,  $TVS$  toplam sınıflandırılan veri sayısını ve  $OSD$  ortalama sınıflandırma başarısını ifade eder.



## 2. YAPILAN ÇALIŞMALAR

### 2.1. Elektronik Burun Deney Düzeneği

Bu çalışmada kullanılan düzenek, KTÜ BAP birimi tarafından 2010-2011 yılları arasında desteklenen, 'Elektronik Burunla Koku Tanıma Sistemi' adlı projede gerçekleştirilen devredir. Bu devre ve yazılımı yeniden güncellenerek bu tez çalışmasında kullanılmıştır.

Yapılan çalışmada elektronik burun devresi yardımıyla, demlenmiş Doğu Karadeniz çayının kokusundan yararlanılarak, çeşitlerine göre sınıflandırılması yapılmıştır.

#### 2.1.1. Kullanılan Ekipmanlar

Bu tez çalışmasında yapılan deneylerde; elektronik burun, veri alma kartı, bilgisayar, hava pompası ve vanalar kullanılmıştır. Bu ekipmanlar elektronik burun ile yapılan koku analizlerinde kullanılan standart ekipmanlardır.

Elektronik burun deney düzeneği, fiziksel ortamda bulunan UOB'ye ait değerlerin elde edilmesinde kullanılan sistemler bütünüdür. Pek çok cihazı ve parçayı içerisinde barındırır. Bu deney düzeneğinde kullanılan araç gereçlerde koku tutmayan ve ısınmayan parçaların kullanılmasına dikkat edilir.

Şekil 14'te elektronik burun deney düzeneğinde, UOB'nin hareketini ortamdan izole bir şekilde sağlayan deney ekipmanları gösterilmiştir. Deney düzeneğinde kullanılan hava pompaları sürekli olarak çalışırlar. Selenoid vanaların uygun şekilde ayarlanmasıyla havanın itici etkisi serbest bırakılarak istenilen yere UOB'nin ulaştırılması sağlanır.

Selenoid vanalar, bilgisayarda kullanılan program ile zamanlı olarak açılıp kapanarak elektronik burun deney düzeneğindeki UOB'nin yönlendirmesini sağlamaktadır. Elektronik burun deney düzeneğinde örneğe ait koku haznesinin girişinde 2, sensör haznesinin giriş ve çıkışında da 3 adet olmak üzere toplamda 5 adet selenoid vana kullanılmaktadır.

UOB'nin birimler arası transferinde teflon borulardan faydalanılmıştır. Bunun sebebi teflon boruların havayı sızdırmaması ve üzerinde herhangi bir UOB'yi tutmamasıdır.



(a)



(b)

Şekil 14. UOB iletim sistemi elemanları a) Hava Pompası, b) Selenoid vana ve teflon boru


Örneğe ait koku haznesi olarak cam kavanoz seçilmiştir. Her bir çay türü için farklı olarak 6 adet kavanozdan faydalanılmıştır. Bu kavanozlar, üzerinde teflon boruların giriş ve çıkış yaptığı 2 adet deliği bulunan kapaklarla kapatılmıştır. Koku haznesinin cam olarak seçilmesinin sebebi koku haznesi üzerinde önceki deneylere ait herhangi bir UOB'nin bulunmasının zor olmasıdır. Şekil 15'te deneylerde kullanılan örneğe ait koku haznesi gösterilmiştir.



Şekil 15. Deneylerde kullanılan örneğe ait koku haznesi



Yapılan deneylerde kullanılan sensör haznesi, çevredeki UOB'leri ortamdaki izole etmek için kapalı kutu şeklinde kullanılmıştır. Malzeme olarak ise alüminyum seçilmiştir. Alüminyum seçilmesinin sebebi düzgün yüzey yapısına sahip olmasıdır. Bu sayede deneyler arasındaki sürede hazne temizlenirken UOB'lerin kutu yüzeyine tutunması engellenmiş olur. Şekil 16'da deneylerde kullanılan sensör haznesi gösterilmiştir.



Şekil 16. Elektronik burun deney düzeneğinde kullanılan sensör haznesi


Sensör haznesinde bulunan sensörler; TGS 880, TGS 825, TGS 830, TGS 826, TGS 2610, TGS 2620, TGS 2602 ve TGS 2104 tipi MOS sensörlerdir. Bu sensörlerin tepki verdiği gaz türleri ve direnç değerleri Tablo 2.'de gösterilmiştir.

Sensörler için gerekli yük dirençleri sensör haznesi dışında tutulmuştur. Bunun nedeni sensörlerin kokuyla ilgili referans değerini belirlerken rahat olarak çalışabilmesidir.


Vanaların bilgisayarda yazılan komutlarla uyumlu olarak çalışabilmesi için kontrol arayüz devresine ihtiyaç vardır. Bu kontrol arayüz devresi, bir dizi röleden oluşmaktadır. Bilgisayardan vanaların açılıp kapanması ile ilgili gelecek her türlü aç kapa komutu, arayüz devresindeki röleler sayesinde yapılmaktadır. Şekil 17'de sensör arayüz devresi ve kontrol arayüz devresi verilmektedir.

Tablo 2. Gaz sensörleri, direnç değerleri ve tepki verdiği gazlar

<b>Kullanılan Sensörün Adı</b>	TGS 880	TGS 825	TGS 830	TGS 826	TGS 2610	TGS 2620	TGS 2602	TGS 2104
<b>Direnç Değerleri (k<math>\Omega</math>)</b>	5.183	8.76	3.9	5.58	7.59	2.9	3.565	4.834
<b>Tepki Verdiği Gaz türü</b>	Hidrojen, Amonyak	Hidrojen sülfid	R-22 R-113	Amonyak	Buton, Propan	Alkoller, çözeltiler, organik kokular	Uçucu ve koku yoğunluğu fazla gazlar	Egzoz gazları



(a)



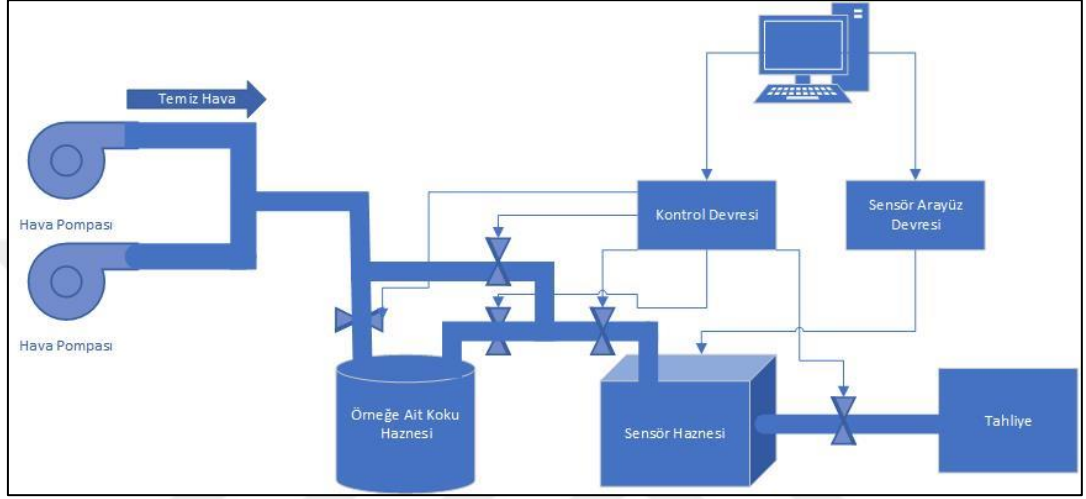
(b)

Şekil 17. a) Sensör arayüz devresi, b) Kontrol arayüz devresi

Devredeki sensörlerden veri okunması ve kontrol devrelerinin sistematik olarak çalışması için bilgisayarda MATLAB programından faydalanılmıştır. Verilerin sensörlerden elde edilmesinde National Instrument'e ait DAQ 6259 veri okuma kartı kullanılmıştır.

### 2.1.2. Elektronik Burun Deneý Düzeneyinin Çalıřma Sistemi

Doęu Karadeniz'e özđü çaylarla hazırlanan çay içeceęinin analizine iliřkin yapılan deneylerde kullanılan elektronik burun deneý düzeneyine ait blok řema řekil 18'de gösterilmiřtir.



řekil 18. Elektronik burun deneý düzeneyi blok řeması

řekil 18'de görüldüęü gibi elektronik burun deneý düzeneyi oldukça basit yapıdadır. Yapılan deneylerde elektronik burun deneý düzeneyi kullanımında izlenen adımlar ařaęıda maddeler halinde sıralanmıřtır.

1. 6 adet çaya ait her bir çaydan 3'er gram alınarak koku haznesi olarak kullanılan cam kavanozlara yerleřtirilmiřtir.
2. Çayları demlemek için üzerlerine 27 gram kaynamıř su ilave edilmiřtir.
3. Her bir çay için demleme süresi 15 dakika olarak belirlenmiř ve hemen deneylerine bařlanmıřtır.
4. Koku haznesi sisteme yerleřtirildikten sonra hava pompaları vasıtasıyla, sensör haznesini temizlemek için 60 saniye boyunca temiz hava uygulanmıřtır.
5. Ön temizleme iřleminden sonra vanalar uygun olarak deęiřtirilip sensör haznesine 50 saniye boyunca örnek kokusunun iletilmesi saęlanmıřtır.

6. Kokunun taşınma işlemi bittiğinde sensör haznesine yerleşen kokunun sensörler tarafından ölçümlerinin alınabilmesi için koku 30 saniye boyunca sensör haznesine hapsedilmiştir.
7. Son olarak; sensör haznesinin örnek kokudan temizlenmesi için, 125 saniye boyunca hava pompalarından temiz hava verilerek sistemin son temizleme aşaması yapılmıştır.

Bu adımlar esnasında selenoid vanaların açık ya da kapalı konuma gelmeleri kontrol devresi ile sağlanmış, sensör ölçümleri ise sensör arayüz devresi tarafından alınmıştır.

## 2.2. Yapılan Çalışmalar

Bu yüksek lisans tez çalışmasında yapılan işlemler şekil 19'da gösterilen blok şemalardaki aşamalar takip edilerek yapılmıştır.




Şekil 19. Yapılan çalışmalara ait blok şeması

### 2.2.1. UOB Ölçümlerinin Yapılması


UOB ölçümleri yapılan çalışmanın en önemli kısmını oluşturmaktadır Bu kısımda yapılacak hassas ölçümler ile daha iyi sonuçlar elde edilecektir. Sistem çalışmaya başlamadan önce her bir deneyde 3 kez arka arkaya referans gaz olarak kullanılan ortam havasına ait ölçümler alınmıştır. Bunun sebebi referans gaza ait bilgiler kullanılarak UOB ile referans gazın birbirinden ayırt edilmesini sağlamaktır. Alınan ortam havasına ait bilgilerde ilk anlarda sensörlerin kararsızlıklarından dolayı çeşitli sapmalar meydana gelmiştir. Ancak yeteri kadar bir süre beklenildiğinde sensör kararlılıkları oluşmuştur. Yapılan çalışmada ise sensörlerin kararlılık seviyeleri belirlenerek sadece bu kısımları

kullanılmıştır. Şekil 20’de deneyler öncesinde standart olarak alınan ortam havasına ait ölçümler verilmiştir.


Ortam havasına ait ölçümler referans olarak alınıp kaydedildikten sonra sırasıyla çayların elektronik burun ile ölçümleri yapılmıştır. Bu bağlamda deneyler sonucunda elde edilen UOB’lere ilişkin sayısal bilgilerle oluşturulan grafikler Şekil 21, Şekil 22, Şekil 23, Şekil 24, Şekil 25 ve Şekil 26’daki gibi olmuştur.



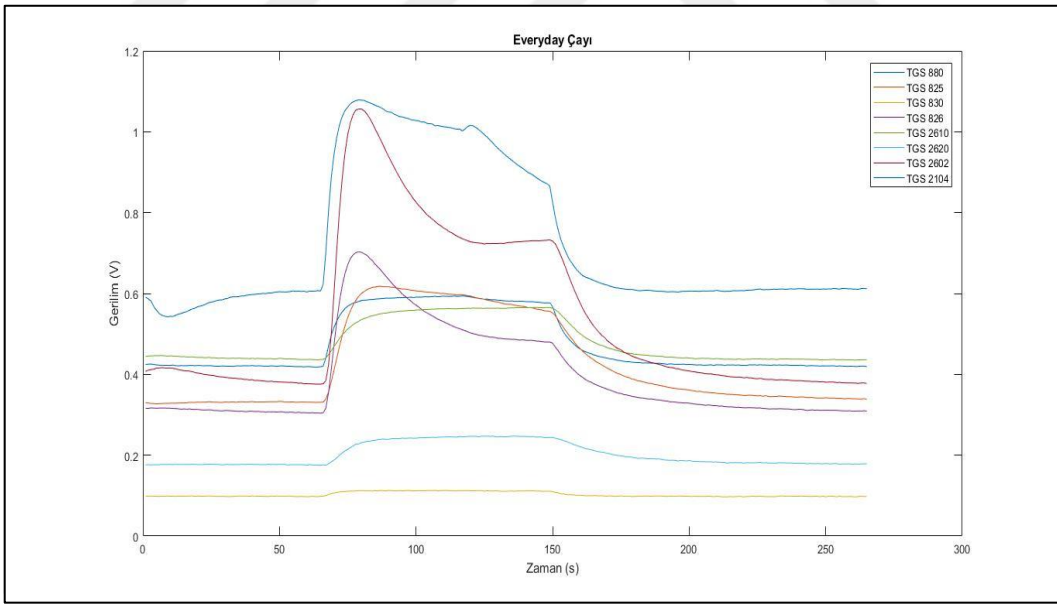
Şekil 20. Referans olarak alınan ortam havasına ait sensör ölçümleri




Şekil 21. Bergamot çayına ait sensör ölçümleri




Şekil 22. Çamlıca çayına ait sensör ölçümleri




Şekil 23. Everyday çayına ait sensör ölçümleri



Şekil 24. Hazine çayına ait sensör ölçümleri



Şekil 25. Regular çayına ait sensör ölçümleri




Şekil 26. Tomurcuk çayına ait sensör ölçümleri

Elde edilen sayısal bilgilerle oluşturulan grafikler incelendiğinde; Çamlıca Filizi, Hazine, Everyday ve Regular çaylarından elde edilen ölçümlerin birbirlerine daha yakın, Tomurcuk ve Bergamot çaylarından elde edilen örneklerin ise kokularının birbirlerinden ve diğer çaylardan daha farklı olduğu sonucuna varılmıştır.


### 2.2.2. Referans Gazın Çıkartılması

Yapılan çalışmalarda referans olarak kullanılan ortam havası, hava pompaları ile itilerek UOB'ler ile birlikte sensör haznesine geldikleri anda, sensörler ile tepkimeye girerek meydana gelen sayısal işareti değiştirebilirler. Bu gibi durumlar hatalı ölçümler yapmaya sebep olur. Bu gibi durumları ortadan kaldırmak için deneylere başlamadan önce ortam havasından referans olarak alınan koku örneğine ait ölçümler, deney esnasında yapılan ölçümlerden çıkartılarak referans gazın etkisi ortadan kaldırılır. Şekil 27, Şekil 28, Şekil 29, Şekil 30, Şekil 31 ve Şekil 32'de gösterilen şekillerde, daha önce alınan çay deneylerine ait ölçümlerden, referans ortam havasının çıkartılması ile elde edilen sayısal verilere ait şekiller verilmiştir.

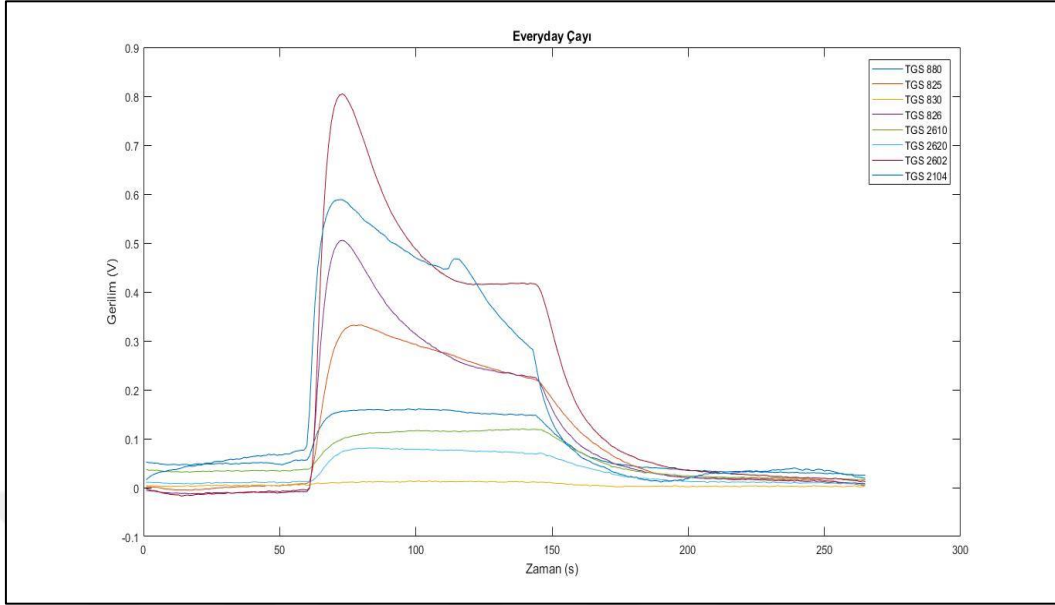





Şekil 27. Referans gazı çıkartılmış Bergamot çayına ait sensör ölçümleri



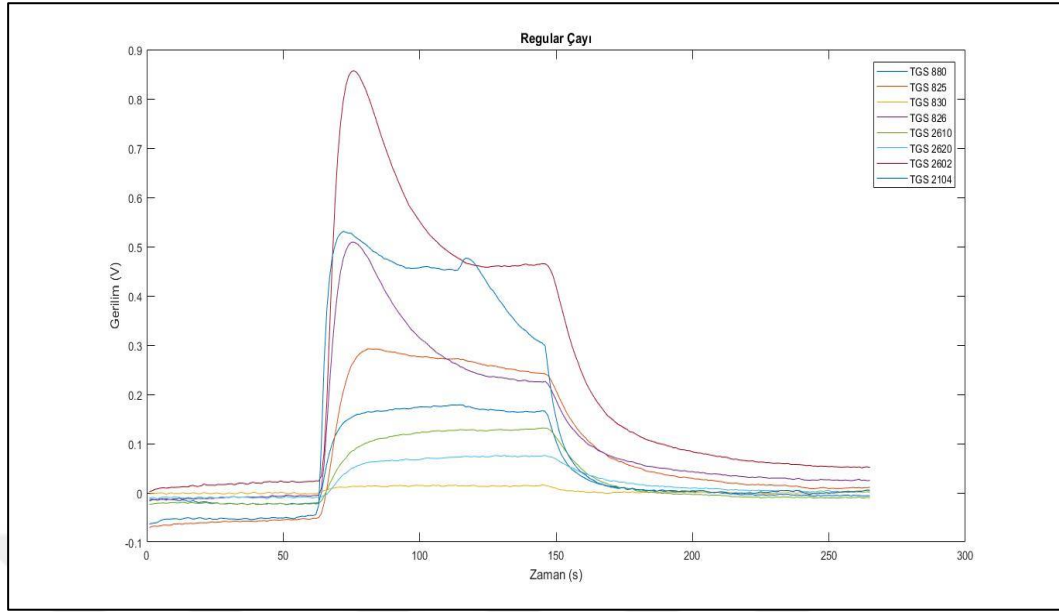
Şekil 28. Referans gazı çıkartılmış Çamlıca çayına ait sensör ölçümleri




Şekil 29. Referans gazı çıkartılmış Everyday çayına ait sensör ölçümleri



Şekil 30. Referans gazı çıkartılmış Hazine çayına ait sensör ölçümleri



Şekil 31. Referans gazı çıkartılmış Regular çayına ait sensör ölçümleri



Şekil 32. Referans gazı çıkartılmış Tomurcuk çayına ait sensör ölçümleri

Referans gazı çıkartıldıktan sonra şekiller incelendiğinde her bir sensör üzerinde oluşan etki farklı olmuştur. Bunun sebebi, her bir sensörün özellikle farklı bir koku molekülü ile ilişkili çalışıyor olmasıdır. İncelendiğinde kokulara en çok sırasıyla; TGS 2602, TGS,


2104, TGS 826, TGS 825, TGS 880, TGS, 2620, TGS 2610 ve TGS 830 sensörleri tepki vermiştir.

### 2.2.3. Referans Düzeltmesi


Referans düzeltmesi, her bir sensörün aynı başlangıç koşulları altında çalışmasını sağlamak için kullanılan bir yöntemdir. Bir önceki bölümde anlatılan referans gazın çıkartılması ile birlikte referans düzeltmesi yapılabilir. Referans düzeltmesi yapmak için her bir sensörün deneye başlangıç anındaki ilk değeri alınarak deney esnasında elde edilen tüm ölçüm değerlerinden çıkarılır. Bu sayede tüm sensörlerin aynı başlangıç koşullarında ölçüm yapmaları sağlanmış olur. Bu tez çalışmasında kullanılan yöntem (43) denklemi ile ifade edilmiştir.

$$V_{d,k,s} = V_{k,s}(t_{k0}) - V_{k,s}(t_1) \quad \forall d, s, k \quad (43)$$


(43) denklemi kullanılarak yapılan işlemlerde Şekil 33, Şekil 34, Şekil 35, Şekil 36, Şekil 37 ve Şekil 38'e ait referans düzeltmesi yapılmış sayısal işaretlere ilişkin grafikler verilmiştir. Şekiller incelendiğinde tüm sensörlerin aynı başlangıç noktasından başladığı görülmektedir.




Şekil 33. Referans düzeltmesi yapılmış Bergamot çayına ait sensör ölçümleri




Şekil 34. Referans düzeltmesi yapılmış Çamlıca çayına ait sensör ölçümleri




Şekil 35. Referans Düzeltmesi yapılmış Everyday çayına ait sensör ölçümleri



Şekil 36. Referans düzeltmesi yapılmış Hazine çayına ait sensör ölçümleri



Şekil 37. Referans düzeltmesi yapılmış Regular çayına ait sensör ölçümleri



Şekil 38. Referans düzeltmesi yapılmış Tomurcuk çayına ait sensör ölçümleri


Referans gazın çıkartılması ile birlikte tüm sensörlerin aynı başlangıç noktasından başlaması sağlanmıştır. Bu sayede sensörlerde meydana gelecek kaymaların engellenmesi amaçlanmıştır.

#### 2.2.4. İletkenlik Dönüşümü


Yapılan bu tez çalışmasında sensörlerden gelen sayısal işaretler, sensörlerde bulunan gerilim bölücü devrelerinden faydalanılarak elde edildiği için tüm ölçümler gerilim değişikliğine bağlı olarak ortaya çıkmıştır. Yapılan çalışmalarda gerilim değeri kullanıldığı gibi aynı zamanda iletkenlik değerleri de kullanılabilir. Bu çalışmada iletkenlik değerlerinden faydalanılmıştır. Gerilim değeri iletkenlik değerine dönüştürülürken (44) denkleminde faydalanılmıştır.

$$G_{n,s}^R(t) = \frac{V_{n,s}^R}{(V_c - V_{n,s}^R)R_{L,S}} \quad (44)$$

Gerilim değeri, iletkenlik değeriine dönüşükten sonra ortaya çıkan sayısal işaretlere ilişkin grafikler aşağıda verilen Şekil 39, Şekil 40, Şekil 41, Şekil 42, Şekil 43 ve Şekil 44'teki gibi oluşmuştur.




Şekil 39. İletkenlik dönüşümü yapılmış Bergamot çayına ait sensör ölçümleri




Şekil 40. İletkenlik dönüşümü yapılmış Çamlıca çayına ait sensör ölçümleri







Şekil 41. İletkenlik dönüşümü yapılmış Everyday çayına ait sensör ölçümleri



Şekil 42. İletkenlik dönüşümü yapılmış Hazine çayına ait sensör ölçümleri



Şekil 43. İletkenlik dönüşümü yapılmış Regular çaya ait sensör ölçümleri



Şekil 44. İletkenlik dönüşümü yapılmış Tomuruk çaya ait sensör ölçümleri

İletkenlik dönüşümü uygulanan sayısal işaretlerin grafikleri incelendiğinde şekil olarak referans dönüşümü yapılmadan önceki şeklin bozulmadığı görülmüştür. Ancak

gerilim deęerleri ve iletkenlik deęerleri kıyaslandığında iletkenlik deęerlerinin daha düşük olduęu grlmřtr.

### 2.2.5. z nitelik ıkarma

z nitelik ıkarma iřlemi veri boyutunu azaltmak iin orijinal veriden, veriyi en iyi temsil edecek řekilde gerekli zelliklerin ıkartılarak biraraya getirilmesi iřlemidir. Her veri tr farklı olacaęı iin birden fazla z nitelik ıkarma yntemi vardır. Veriyi en iyi temsil edecek z nitelięi bulmak ise deneme-yanılma yntemi ile bulunmaktadır.

ay verisinden ıkarılan bazı z nitelikler ařaęıdaki gibidir;

1. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki deęerlerin ykselme zamanına ait trevi
2. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki deęerlerin maksimum olduęu zamana ait trevi
3. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki deęerlerin alalma zamanına ait trevi
4. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki integrali
5. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki enerjisi
6. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki basıklık katsayıları
7. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki arpıklık katsayıları
8. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki maksimum deęerleri
9. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki minimum deęerleri
10. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki varyansı
11. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki ortalaması
12. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki standart sapması
13. Her bir sensrden elde edilen iletkenlik deęerlerinin (126x8) boyutundaki entropisi

14. Her bir sensörden elde edilen iletkenlik değerlerine ait tüm özneliklerin (126x13) boyutundaki temel bileşen analizi ile indirgenmiş verisi
  15. Her bir sensörden elde edilen iletkenlik değerlerine ait 1,2,3,4,9 ve 10. özneliklerin (126x6) boyutundaki temel bileşen analizi ile indirgenmiş verisi
  16. Her bir sensörden elde edilen iletkenlik değerlerinin alt örnek indirgeme yöntemi ile indirgenmiş (126x1568), (126x784), (126x392), (126x197), (126x99), (126x50) ve (126x8) boyutundaki veriler
  17. Her bir sensörden elde edilen iletkenlik değerlerinin, sensörlere koku verilemeye başlandıktan sonraki ilk 50 saniye sonraki (126x50) boyutundaki verisi
  18. Her bir sensörden elde edilen iletkenlik değerlerinin, kokunun koku haznesine hapsedildiği andan itibaren 30 saniye sonraki (126x30) boyutundaki verisi
  19. Her bir sensörden elde edilen iletkenlik değerlerinin, koku haznesinin temizlenmeye başladığı andan sonraki ilk 50 saniye sonraki (126x50) boyutundaki verisi
- öznelik olarak kullanılmıştır.

### 3. BULGULAR

Bu tez çalışmasında özniteliklere bağlı olarak Karar Ağaçları, Destek Vektör Makinesi, k-En Yakın Komşu, Doğrusal Ayırma Analizi ve Sınıflandırıcı Toplulukları Yöntemi ile sınıflandırma çalışmaları yapılmıştır. Her bir sınıflandırmada 10 katlı çapraz doğrulama yöntemi kullanılmıştır. Elde edilen sonuçlara ilişkin tablolar aşağıdaki şekilde olmuştur.

Normalize edilmemiş verinin karar ağaçları ile sınıflandırılmasına ilişkin sonuçlar Tablo 3'te verilmiştir. Tablo 3'te sınıflandırma başarıları incelendiğinde en yüksek başarı oranının bağlı ağaç sınıflandırıcısı ile 1,2,3,4,5,6 ve 7 öznitelikleri kullanılarak %56,3 olarak elde edildiği görülmektedir.

Tablo 3. Normalize edilmemiş verinin karar ağaçları ile sınıflandırılmasına ilişkin sınıflandırma Başarıları

Sınıflandırma Başarısı (%)							
Kul. Öznit.	Kul. Alg.	Karar Ağacı (4 dallı)	Karar Ağacı (20 dallı)	Karar Ağacı (100 dallı)	Kuvvetlendirilmiş Ağaç	Bağlı Ağaç	Rastgele Alt Örnekleme ile Kuvvetlendirilmiş Ağaç
1,2,3		47.6	42.1	42.1	46.8	46.0	45.2
1,2,3,4		51.6	50.8	50.8	46.0	52.4	46.8
1,2,3,4,5		49.2	50.0	50.0	49.2	50.0	47.6
1,2,3,4,5,6		<b>54.0</b>	43.7	43.7	44.4	44.4	44.4
1,2,3,4,5,6,7		51.6	46.8	46.8	50.8	<b>56.3</b>	50.0
1,2,3,4,5,6,7,8		50.0	42.9	42.9	42.4	48.4	46.8
1,2,3,4,5,6,7,8,9		49.2	<b>52.4</b>	<b>52.4</b>	50.8	49.2	50.8
1,2,3,4,5,6,7,8,9,10		49.2	42.9	42.9	50.0	47.6	42.9
1,2,3,4,5,6,7,8,9,10,11		52.4	48.4	48.4	48.4	50.8	50.8
1,2,3,4,7,8,9,10,11		52.4	<b>52.4</b>	52.4	48.4	47.6	53.2
1,2,3,4,7,8,9,10		50.0	48.4	48.4	51.6	49.2	46.0
1,2,3,6		51.6	51.6	51.6	46.8	50.0	<b>52.4</b>
1,2,3,7		<b>54.0</b>	50.0	50.0	<b>52.4</b>	49.2	49.2
1,2,3,4,8		50.0	48.4	48.4	48.4	53.2	51.6
1,2,3,4,9		51.6	50.0	50.0	<b>52.4</b>	47.6	51.6
1,2,3,9		49.2	43.7	43.7	42.1	52.4	43.7
1,2,3,4,9,11		46.8	46.0	46.0	43.7	46.0	42.9
1,2,3,4,5,9,11		50.8	50.0	50.0	44.4	51.6	49.2
14		44.4	44.4	44.4	45.2	49.2	46.0
15		50.0	<b>52.4</b>	<b>52.4</b>	50.0	50.0	47.6
1,2,3,4,6,7,8,9,10,11,12,13		49.2	43.7	43.7	46.0	54.0	44.4

Normalize edilmiş verinin karar ağaçları ile sınıflandırılmasına ilişkin sınıflandırma başarıları Tablo 4’te verilmiştir. Tablo 4 incelendiğinde en yüksek başarı oranı bağlı ağaç algoritması ile 1,2 ve 3 öznitelikleri kullanılarak %57,1 olarak elde edilmiştir. Aynı algoritmalar ve öznitelikler kullanılmasına rağmen normalizasyon işleminin yapılmış olması başarı oranında az da olsa yükselmesine neden olmuştur.

Tablo 4. Normalize edilmiş verinin karar ağaçları ile sınıflandırılmasına ilişkin sınıflandırma başarıları

Sınıflandırma Başarısı (%)						
Kul. Öznit \ Kul. Alg.	Karar Ağacı (4 dallı)	Karar Ağacı (20 dallı)	Karar Ağacı (100 dallı)	Kuvvetlendirilmiş Ağaç	Bağlı Ağaç	Rastgele Alt Örneklemeye ile Kuvvetlendirilmiş Ağaç
1,2,3	35.7	45.2	45.2	<b>54.0</b>	<b>57.1</b>	48.4
1,2,3,4	37.3	36.5	36.5	28.6	47.6	32.5
1,2,3,4,5	42.1	42.9	42.9	46.8	47.6	45.2
1,2,3,4,5,6	46.8	46.0	46.0	44.4	50.8	47.6
1,2,3,4,5,6,7	47.6	49.2	49.2	43.7	56.3	52.4
1,2,3,4,5,6,7,8	42.9	47.6	47.6	40.5	54.0	45.2
1,2,3,4,5,6,7,8,9	43.7	45.2	45.2	43.7	49.2	42.9
1,2,3,4,5,6,7,8,9,10	45.2	45.2	45.2	40.5	45.2	46.0
1,2,3,4,5,6,7,8,9,10,11	45.2	44.4	44.4	53.2	44.4	44.4
1,2,3,4,7,8,9,10,11	48.4	46.8	46.8	48.4	45.2	46.8
1,2,3,4,7,8,9,10	52.4	42.9	42.9	46.8	50.0	42.1
1,2,3,6	45.2	42.9	42.9	42.1	52.4	45.2
1,2,3,7	<b>54.8</b>	<b>50.0</b>	<b>50.0</b>	52.4	50.0	<b>50.8</b>
1,2,3,4,8	38.9	47.6	47.6	38.1	45.2	46.8
1,2,3,4,9	31.7	33.3	33.3	39.7	44.4	33.3
1,2,3,9	41.3	41.3	41.3	41.3	46.8	37.3
1,2,3,4,9,11	39.7	31.7	31.7	38.9	49.2	35.7
1,2,3,4,5,9,11	46.8	47.6	47.6	47.6	47.6	48.4
14	45.2	45.2	45.2	44.4	43.7	48.4
15	42.9	44.4	44.4	40.5	41.3	40.5
1,2,3,4,6,7,8,9,10,11,12,13	43.7	41.3	41.3	40.5	48.4	46.0

Normalize edilmemiş ve normalize edilmiş verinin doğrusal ayırım analizi ile sınıflandırılmasına ilişkin sınıflandırma başarıları Tablo 5’de verilmiştir. Tablo 5 incelendiğinde en yüksek başarı oranının alt uzay ayırım analizi (normalize edilmiş) ile 1,2,3,4,7,8,9 ve 10 öznitelikleri kullanılarak %70,6 olarak elde edildiği görülmüştür.

Normalize edilmiş veri ve edilmemiş verilere ait sınıflandırma başarıları karşılaştırıldığında genel olarak normalize edilmiş verilerde başarı oranının yüksek olduğu görülmüştür.

Tablo 5. Normalize edilmiş ve normalize edilmemiş verinin doğrusal ayırım analizi ile sınıflandırılmasına ilişkin sınıflandırma başarıları

Sınıflandırma Başarısı (%)				
Kul. Alg. Kul. Öznit.	Doğrusal Ayırım Analizi (Normalize edilmemiş)	Alt Uzay Doğrusal Ayırım Analizi (Normalize edilmemiş)	Doğrusal Ayırım Analizi (Normalize edilmiş)	Alt Uzay Ayırım Analizi (Normalize edilmiş)
1,2,3	54.8	50.0	55.6	57.1
1,2,3,4	61.1	50.8	54.0	48.4
1,2,3,4,5	59.5	46.0	57.1	49.2
1,2,3,4,5,6	58.7	51.6	57.9	55.6
1,2,3,4,5,6,7	59.5	55.6	61.1	59.5
1,2,3,4,5,6,7,8	55.6	<b>64.3</b>	57.9	60.3
1,2,3,4,5,6,7,8,9	58.7	58.7	57.9	65.1
1,2,3,4,5,6,7,8,9,10	54.0	<b>64.3</b>	55.6	66.7
1,2,3,4,5,6,7,8,9,10,11	54.8	61.9	57.9	66.7
1,2,3,4,7,8,9,10,11	58.7	63.5	59.5	68.3
1,2,3,4,7,8,9,10	<b>61.9</b>	61.9	62.7	<b>70.6</b>
1,2,3,6	58.7	55.6	<b>65.9</b>	54.0
1,2,3,7	59.5	54.0	63.5	59.5
1,2,3,4,8	54.8	51.6	59.6	51.6
1,2,3,4,9	62.7	54.8	58.7	57.1
1,2,3,9	56.3	56.3	61.9	57.1
1,2,3,4,9,11	65.1	56.3	61.1	60.3
1,2,3,4,5,9,11	57.9	57.9	59.5	57.9
14	50.0	48.4	Hatalı	47.6
15	44.4	45.2	36.5	39.7
1,2,3,4,6,7,8,9,10,11,12 ,13	Hatalı	60.3	46.0	62.7

Normalize edilmemiş verinin destek vektör makineleri ile sınıflandırılmasına ilişkin sınıflandırma başarıları Tablo 6’da verilmiştir. Tablo 6 incelendiğinde en yüksek başarı

oranının kuadratik destek vektör makineleri ile 1,2,3,4,5,6 ve 7 öznitelikleri kullanılarak %57.1 olarak elde edildiği görülmüştür.

Tablo 6. Normalize edilmemiş verinin destek vektör makineleri ile sınıflandırılmasına ilişkin sınıflandırma başarıları

		Sınıflandırma Başarısı (%)					
Kul. Öznit.	Kul. Alg.	Doğrusal Destek Vektör Makineleri	Kuadratik Destek Vektör Makineleri	Kübik Destek Vektör Makineleri	Gauss Destek Vektör Makineleri (Kernel Oranı= 0.71)	Gauss Destek Vektör Makineleri (Kernel Oranı= 2.8)	Gauss Destek Vektör Makineleri (Kernel Oranı= 11)
1,2,3		46.0	46.8	46.8	31.0	48.4	34.1
1,2,3,4		<b>50.8</b>	51.6	49.2	31.0	48.4	34.9
1,2,3,4,5		49.2	51.6	48.4	30.2	46.0	34.1
1,2,3,4,5,6		48.4	53.2	47.6	34.9	51.6	32.5
1,2,3,4,5,6,7		45.2	<b>57.1</b>	52.4	32.5	49.2	31.7
1,2,3,4,5,6,7,8		51.6	55.6	<b>55.6</b>	31.0	<b>53.2</b>	34.9
1,2,3,4,5,6,7,8,9		46.0	50.0	46.8	30.2	46.8	33.3
1,2,3,4,5,6,7,8,9,10		46.8	56.3	54.0	31.7	51.6	38.9
1,2,3,4,5,6,7,8,9,10,11		46.8	47.6	50.0	27.0	45.2	31.7
1,2,3,4,7,8,9,10,11		45.2	50.8	49.2	25.4	47.6	37.3
1,2,3,4,7,8,9,10		49.2	52.4	50.8	31.7	51.6	38.1
1,2,3,6		46.0	54.8	50.0	31.0	48.4	32.5
1,2,3,7		48.4	54.0	50.0	32.5	51.6	38.9
1,2,3,4,8		43.7	48.4	46.0	<b>35.7</b>	45.2	36.5
1,2,3,4,9		47.6	46.8	46.0	23.8	45.2	34.9
1,2,3,9		42.9	43.7	40.5	25.4	44.4	33.3
1,2,3,4,9,11		47.6	52.1	50.8	33.3	46.0	40.5
1,2,3,4,5,9,11		45.2	50.0	47.6	28.6	43.7	31.7
14		43.7	52.4	45.2	34.9	50.0	<b>42.9</b>
15		45.2	45.2	48.4	31.7	42.9	41.3
1,2,3,4,6,7,8,9,10,11,12,13		46.8	53.2	50.8	34.1	48.4	37.3

Normalize edilmiş verinin destek vektör makineleri ile sınıflandırılmasına ilişkin sınıflandırma başarıları Tablo 7’de verilmiştir. Tablo 7 incelendiğinde en yüksek başarı oranının gauss destek vektör makineleri (kernel oranı=2.8) ile 1,2,3,4,7,8,9 ve 10 öznitelikleri kullanılarak % 57.1 olarak elde edildiği görülmüştür.



Normalize edilmiş veri ve edilmemiş verilere ait sınıflandırma başarıları karşılaştırıldığında genel olarak normalize edilmiş verilerde başarı oranının yüksek olduğu görülmüştür.

Tablo 7. Normalize edilmiş verinin destek vektör makineleri ile sınıflandırılmasına ilişkin sınıflandırma başarıları

		Sınıflandırma Başarısı (%)					
Kul. Öznit.	Kul. Alg.	Doğrusal Destek Vektör Makineleri	Kuadratik Destek Vektör Makineleri	Kübik Destek Vektör Makineleri	Gauss Destek Vektör Makineleri (Kernel Oranı= 0.71)	Gauss Destek Vektör Makineleri (Kernel Oranı= 2.8)	Gauss Destek Vektör Makineleri (Kernel Oranı= 11)
1,2,3		50.0	52.4	54.8	30.2	51.6	35.7
1,2,3,4		51.6	51.6	52.4	31.7	47.6	41.3
1,2,3,4,5		50.8	56.3	55.6	<b>41.3</b>	50.0	42.9
1,2,3,4,5,6		45.2	57.1	53.2	35.7	50.8	38.9
1,2,3,4,5,6,7		50.8	<b>61.9</b>	57.1	37.3	54.8	43.7
1,2,3,4,5,6,7,8		44.4	59.5	<b>57.9</b>	38.1	55.6	40.5
1,2,3,4,5,6,7,8,9		42.9	54.8	50.8	27.8	52.4	34.1
1,2,3,4,5,6,7,8,9,10		46.8	51.6	52.4	29.4	53.2	41.3
1,2,3,4,5,6,7,8,9,10,11		46.0	54.8	52.4	21.4	50.8	36.5
1,2,3,4,7,8,9,10,11		51.6	54.0	56.3	29.4	53.2	41.3
1,2,3,4,7,8,9,10		<b>54.0</b>	56.3	55.6	30.2	<b>57.1</b>	39.7
1,2,3,6		42.1	57.1	55.6	32.5	46.8	38.9
1,2,3,7		52.4	57.1	57.1	34.9	56.3	40.5
1,2,3,4,8		51.6	54.8	50.8	36.5	49.2	40.5
1,2,3,4,9		55.6	53.2	52.4	29.4	47.6	42.1
1,2,3,9		51.6	54.0	51.6	23.0	49.2	39.7
1,2,3,4,9,11		47.6	47.6	48.4	31.7	46.8	<b>44.4</b>
1,2,3,4,5,9,11		51.6	52.4	54.8	31.0	48.4	40.5
14		44.4	44.4	45.2	36.5	39.7	42.1
15		41.3	46.8	48.4	<b>41.3</b>	40.5	35.7
1,2,3,4,6,7,8,9,10,11,12,13		44.4	56.3	54.8	31.7	54.0	36.5

Normalize edilmemiş verinin k-en yakın komşu ile sınıflandırılmasına ilişkin sınıflandırma başarıları Tablo 8’de verilmiştir. Tablo 8 incelendiğinde en yüksek başarı oranının ağırlıklı k-en yakın komşu ile 1,2,3,4 ve 8 öznitelikleri kullanılarak % 52.4 olarak elde edildiği görülmüştür.

Tablo 8. Normalize edilmemiş verinin k-en yakın komşu ile sınıflandırılmasına ilişkin sınıflandırma başarıları

Sınıflandırma Başarısı (%)							
Kul. Alg. / Kul. Öznit.	k En Yakın Komşu (k=1)	k En Yakın Komşu (k=10)	k En Yakın Komşu (k=100)	Kosinüs k En Yakın Komşu	Kübik k En Yakın Komşu	Ağırlıklı k En Yakın Komşu	Alt uzaylı k En Yakın Komşu
1,2,3	42.9	34.9	26.2	35.7	44.4	34.1	48.4
1,2,3,4	49.2	39.7	25.4	34.9	31.7	48.4	47.6
1,2,3,4,5	46.8	37.3	21.4	38.9	28.6	44.4	44.4
1,2,3,4,5,6	47.6	37.3	21.4	38.9	28.6	44.4	40.5
1,2,3,4,5,6,7	44.4	42.1	19.0	32.5	40.5	45.2	45.2
1,2,3,4,5,6,7,8	50.0	36.5	19.0	34.9	39.7	47.6	48.4
1,2,3,4,5,6,7,8,9	49.2	37.3	23.0	35.7	36.5	45.2	44.4
1,2,3,4,5,6,7,8,9,10	49.2	40.5	21.4	37.3	34.1	48.4	<b>49.2</b>
1,2,3,4,5,6,7,8,9,10,11	48.4	37.3	23.0	35.7	38.9	46.0	46.0
1,2,3,4,7,8,9,10,11	46.8	34.1	23.8	33.3	34.9	49.2	48.4
1,2,3,4,7,8,9,10	49.2	37.3	25.4	38.1	31.0	45.2	47.6
1,2,3,6	40.5	19.8	36.5	38.1	40.5	46.8	42.9
1,2,3,7	46.8	36.5	22.2	34.1	37.3	43.7	<b>49.2</b>
1,2,3,4,8	48.4	41.3	21.4	41.3	34.9	<b>52.4</b>	46.0
1,2,3,4,9	47.6	36.5	22.2	38.1	31.0	44.4	45.2
1,2,3,9	42.9	31.7	21.4	31.7	27.0	39.7	47.6
1,2,3,4,9,11	46.8	40.5	19.8	31.7	32.5	42.9	45.2
1,2,3,4,5,9,11	46.8	35.7	20.6	34.9	31.0	42.9	44.4
14	44.4	26.2	<b>40.5</b>	<b>46.0</b>	<b>48.4</b>	45.2	38.9
15	43.7	<b>43.7</b>	29.4	41.3	41.3	43.7	38.9
1,2,3,4,6,7,8,9,10,11,12,13	<b>50.8</b>	35.7	22.2	35.7	34.9	50.8	46.0

Normalize edilmiş verinin k-en yakın komşu ile sınıflandırılmasına ilişkin sınıflandırma başarıları Tablo 9’da verilmiştir. Tablo 9 incelendiğinde en yüksek başarı oranının alt uzaylı k-en yakın komşu ile 1,2,3,4,5,6,7,8,9 ve 10 öznitelikleri kullanılarak %69.2 olarak elde edildiği görülmüştür. Buna karşın kullanılan öznitelikler ise nolu özniteliklerdir.

Normalize edilmiş veri ve normalize edilmemiş verilere ait sınıflandırma başarıları karşılaştırıldığında genel olarak normalize edilmiş verilerde başarı oranının yüksek olduğu görülmüştür.

Tablo 9. Normalize edilmiş verinin k-en yakın komşu ile sınıflandırılmasına ilişkin sınıflandırma başarıları

Sınıflandırma Başarısı (%)							
Kul. Alg. / Kul. Öznit.	k En Yakın Komşu (k=1)	k En Yakın Komşu (k=10)	k En Yakın Komşu (k=100)	Kosinüs k En Yakın Komşu	Kübik k En Yakın Komşu	Ağırlıklı k En Yakın Komşu	Alt uzaylı k En Yakın Komşu
1,2,3	47.6	41.3	22.2	<b>49.2</b>	40.5	50.8	54.0
1,2,3,4	48.4	43.7	23.0	38.1	41.3	45.2	45.2
1,2,3,4,5	54.8	47.6	24.6	38.9	42.9	<b>53.2</b>	40.5
1,2,3,4,5,6	<b>56.3</b>	38.9	23.8	38.1	41.3	48.4	46.8
1,2,3,4,5,6,7	54.8	38.1	19.8	36.5	38.1	51.6	53.2
1,2,3,4,5,6,7,8	52.4	<b>46.0</b>	22.2	37.3	38.1	50.8	50.8
1,2,3,4,5,6,7,8,9	50.0	44.4	20.6	39.7	46.0	47.6	50.0
1,2,3,4,5,6,7,8,9,10	49.2	49.2	24.6	38.9	45.2	50.8	<b>69.2</b>
1,2,3,4,5,6,7,8,9,10,11	50.8	41.3	26.2	36.5	43.7	50.0	50.8
1,2,3,4,7,8,9,10,11	51.6	46.0	18.3	34.9	<b>48.4</b>	48.4	54.8
1,2,3,4,7,8,9,10	53.2	49.2	15.1	37.3	<b>48.4</b>	50.8	56.3
1,2,3,6	50.0	38.9	23.8	38.1	38.9	52.4	47.6
1,2,3,7	54.0	41.3	17.5	38.9	42.1	49.2	53.2
1,2,3,4,8	49.2	43.7	23.8	39.7	43.7	46.8	35.7
1,2,3,4,9	48.4	45.2	16.7	39.7	44.4	45.2	31.7
1,2,3,9	50.8	45.2	17.5	34.1	43.7	46.8	31.7
1,2,3,4,9,11	49.2	38.9	20.6	40.5	39.7	44.4	29.4
1,2,3,4,5,9,11	53.2	42.9	19.0	32.5	44.4	47.6	34.9
14	41.3	35.7	<b>28.6</b>	38.9	41.3	39.7	44.4
15	44.7	37.3	20.6	38.9	37.3	38.9	43.7
1,2,3,4,6,7,8,9,10,11,12,13	54.0	44.4	20.6	37.3	43.7	<b>53.2</b>	51.6

k-En yakın komşu algoritması kullanılarak yapılan sınıflandırmada, seçilen k değerlerine ait komşuluk değerlerinin ilk 7 komşuluğu incelendiğinde en yüksek sınıflandırma başarıları, k=1 olduğu durumda elde edilmiştir. Buna bağlı olarak incelenen tüm k değerlerine ilişkin sınıflandırma başarıları ise Tablo 10'da gösterilmiştir.

Tablo 10. Normalize edilmiş verinin k-en yakın komşu algoritması kullanılarak en yakın 7 komşusunun sınıflandırma başarıları

Sınıflandırma Başarısı(%)							
Kul. Alg.	k En Yakın Komşu (k=1)	k En Yakın Komşu (k=2)	k En Yakın Komşu (k=3)	k En Yakın Komşu (k=4)	k En Yakın Komşu (k=5)	k En Yakın Komşu (k=6)	k En Yakın Komşu (k=7)
Kul. Öznit.							
1,2,3	47.6	41.3	47.6	47.6	42.1	40.5	35.7
1,2,3,4	48.4	42.1	46.8	37.3	38.1	38.1	38.9
1,2,3,4,5	54.8	<b>52.4</b>	48.4	46	43.7	41.3	36.5
1,2,3,4,5,6	<b>56.3</b>	47.6	49.2	48.4	46	41.3	45.2
1,2,3,4,5,6,7	54.8	48.4	48.4	<b>55.6</b>	46	42.9	<b>47.6</b>
1,2,3,4,5,6,7,8	52.4	51.6	47.6	51.6	<b>50.8</b>	42.9	46
1,2,3,4,5,6,7,8,9	50.0	46	50	46.8	38.9	42.9	40.5
1,2,3,4,5,6,7,8,9,10	49.2	49.2	49.2	43.7	41.3	43.7	44.4
1,2,3,4,5,6,7,8,9,10,11	50.8	47.6	51.6	46	45.2	42.1	42.9
1,2,3,4,7,8,9,10,11	51.6	42.1	47.6	46.8	39.7	38.1	39.7
1,2,3,4,7,8,9,10	53.2	47.6	47.6	48.4	41.3	40.5	46
1,2,3,6	50.0	46.8	<b>50.8</b>	51.6	46	<b>47.6</b>	45.2
1,2,3,7	54.0	46	46.8	46.8	41.3	40.5	40.5
1,2,3,4,8	49.2	50.8	47.6	42.9	38.1	37.3	42.1
1,2,3,4,9	48.4	34.9	38.1	34.9	34.9	30.2	32.5
1,2,3,9	50.8	39.8	44.4	41.3	38.9	35.7	38.9
1,2,3,4,9,11	49.2	38.9	44.4	43.7	42.9	34.9	39.7
1,2,3,4,5,9,11	53.2	38.1	36.5	49.2	38.9	34.9	38.1
14	41.3	44.4	46	50	47.6	47.6	46
15	44.7	49.2	47.6	46	46.8	43.7	42.1
1,2,3,4,6,7,8,9,10,11,12,13	54.0	49.2	49.2	48.4	47.6	45.2	39.7

Yapılan bu tez çalışmasında alt örnekleme yöntemi ile boyut azaltılarak öznelikler çıkarılmıştır. Bunu yapmak için sensörlerin saniye başına aldıkları örnekler üzerinden saniyede 10 örnek, saniyede 1 örnek, 2 saniyede 1 örnek, 4 saniyede 1 örnek, 8 saniyede 1

örnek, 16 saniyede 1 örnek, 32 saniyede 1 örnek ve 224 saniyede 1 örnek alınacak şekilde veri kümeleri oluşturulmuş ve kullanılan sınıflandırma algoritmalarıyla da sınıflandırma başarıları hesaplanmıştır. Tablo 11’de sınıflandırma algoritmalarının her bir öznitelik için bulunan sınıflandırma başarıları gösterilmiştir.

Karar ağacı sınıflandırıcısında en yüksek sınıflandırma başarısına bağlı ağaç sınıflandırıcısında 32 saniyede 1 örnek alınarak % 54 olarak elde edilmiştir. Saniye başına alınan örnek sayısı sınıflandırma başarısında alınan örnek sayısından bağımsız olarak değişmiştir. Ancak en yüksek sınıflandırma başarıları 4 saniyede 1 örnek alındığı durumda elde edilmiştir.

Doğrusal ayırım analizinde en yüksek sınıflandırma başarısı alt uzay doğrusal ayırım analizinde 1 saniyede 1 örnek, 8 saniyede 1 örnek ve 16 saniyede 1 örnek alınarak % 59.5 olarak elde edilmiştir. Yine bu durumda da saniye başına alınan örnek sayısı sınıflandırma başarısında alınan örnek sayısından bağımsız olarak değişmiştir.

Destek vektör makinelerinde en yüksek sınıflandırma başarısı kübik destek vektör makinelerinde 32 saniyede 1 örnek alınarak % 57.1 olarak elde edilmiştir. Bu durumda da saniye başına alınan örnek sayısı sınıflandırma başarısında alınan örnek sayısından bağımsız olarak değişmiştir. Ancak en yüksek sınıflandırma başarıları çoğunlukla kuadratik destek vektör makineleri kullanılarak elde edilmiştir.

k-en yakın komşu algoritmasında en yüksek sınıflandırma başarısı kübik destek vektör makinelerinde 8 saniyede 1 örnek ve 16 saniyede 1 örnek alınarak % 54.0 olarak elde edilmiştir. Bu durumda da saniye başına alınan örnek sayısı sınıflandırma başarısında alınan örnek sayısından bağımsız olarak değişmiştir. Ancak en yüksek sınıflandırma başarıları çoğunlukla alt uzay k-en yakın komşu sınıflandırıcısı kullanılarak elde edilmiştir.

Çaylara ait verilerin grafikler incelendiğinde belirgin şekilde değer değişikliği gösteren sensörlerin TGS 2610, TGS 2602 ve TGS 2104 olduğu belirlenmiştir. Buna bağlı olarak sensör optimizasyonu, kullanılan diğer sensörlere ait verilerin çıkarılmasıyla yapılmıştır. Sadece 3 sensöre ait verilerle oluşturulan özniteliklerde sınıflandırma algoritmalarının başarıları ölçülmüştür. Bunun yanında 6 çay türüne ait verilerin incelenmesinin yanında bazı çay türlerinin de ayrıca sınıflandırma sonuçları araştırılmıştır. Bu çaylar Bergamot çayı, Tomurcuk çayı ve Çamlıca Filizi çayıdır. En yüksek sınıflandırma başarısına ise sensör optimizasyonu yapılmış olan bu 3 çayın kullanılmasıyla ulaşılmıştır. En yüksek sınıflandırma başarısı olan % 92.1’e ise doğrusal destek vektör makineleri yöntemi kullanılarak ulaşılmıştır.

Tablo 11. Alt örnekleme yöntemiyle boyutu azaltılan verinin sınıflandırılmasına ilişkin sınıflandırma başarıları

Sınıflandırma Algoritmaları	Sınıflandırma Başarısı (%)							
	Sn de 10 örnek	Sn de 1 örnek	2 sn 1 örnek	4 sn 1 örnek	8 sn 1 örnek	16 sn 1 örnek	32 sn 1 örnek	224 sn 1 örnek
<b>Karar Ağaçları</b>								
Karar Ağacı (4 dallı)	<b>47.6</b>	51.6	50.0	<b>53.2</b>	50.8	50.8	49.2	46.0
Karar Ağacı (20 dallı)	46.8	46.0	51.6	<b>53.2</b>	50.0	50.0	43.7	43.7
Karar Ağacı (100 dallı)	<b>47.6</b>	46.0	51.6	<b>53.2</b>	46.0	46.0	57.1	43.7
Kuvvetlendirilmiş Ağaç	42.9	47.6	50.8	47.6	47.6	47.6	49.2	<b>50.0</b>
Bağlı Ağaç	46.8	<b>54.0</b>	48.4	51.6	<b>52.4</b>	<b>52.4</b>	<b>54.0</b>	46.0
Rastgele Alt Örnekleme ile Kuvvetlendirilmiş Ağaç	42.9	47.6	50.0	50.0	46.8	46.8	44.4	43.7
<b>Doğrusal Ayrım Analizi</b>								
Doğrusal Ayrım Analizi	Başarı-sız	57.9	49.2	43.7	50.8	50.8	<b>57.1</b>	42.9
Alt Uzay Doğrusal Ayrım Analizi	<b>52.4</b>	<b>59.5</b>	<b>56.3</b>	<b>53.2</b>	<b>59.5</b>	<b>59.5</b>	49.2	<b>45.2</b>
<b>Destek Vektör Makineleri</b>								
Doğrusal Destek Vektör Makineleri	İptal	49.2	45.2	43.7	48.4	48.4	46.8	45.2
Kuadratik Destek Vektör Makineleri	İptal	<b>52.4</b>	<b>56.3</b>	<b>54.0</b>	<b>55.6</b>	<b>55.6</b>	54.0	53.2
Kübik Destek Vektör Makineleri	İptal	51.6	2.4	0.8	54.8	54.8	<b>57.1</b>	<b>54.0</b>
Basit Gauss Destek Vektör Makineleri	İptal	38.1	43.7	38.9	45.2	45.2	42.1	42.9
Normal Gauss Destek Vektör Makineleri	İptal	48.4	46.8	47.6	51.6	51.6	36.5	42.1
Kaba Gauss Destek Vektör Makineleri	İptal	35.7	19.8	33.3	35.7	35.7	37.3	33.3
<b>k-En Yakın Komşu</b>								
k-En Yakın Komşu (k=1)	İptal	46.0	47.6	45.2	<b>54.0</b>	<b>54.0</b>	45.2	42.1
k-En Yakın Komşu (k=3)	İptal	46.8	43.7	50.0	48.4	44.4	47.6	<b>50.0</b>
k-En Yakın Komşu (k=5)	İptal	42.1	41.3	48.4	44.4	47.6	48.4	42.9
k-En Yakın Komşu (k=7)	İptal	44.4	46.0	42.9	44.4	43.7	45.2	43.7
Kosinüs k En Yakın Komşu	39.7	31.7	31.7	32.5	34.9	34.9	31.7	38.1
Kübik k En Yakın Komşu	41.3	38.9	32.5	38.9	34.9	34.9	37.3	42.1
Alt Uzay k En Yakın Komşu	<b>50.8</b>	<b>51.6</b>	<b>48.4</b>	<b>51.6</b>	46.8	46.8	<b>51.6</b>	41.3
Ağırlıklı k En Yakın Komşu	43.7	45.2	45.2	43.7	44.4	44.4	46.8	47.6

Tablo 12. Sensör optimizasyonu yapılmış ve yapılmamış bazı çayların sınıflandırma başarısı

Sınıflandırma Algoritmaları	Sınıflandırma Başarısı (%)					
	Bergamot Tomurcuk	Bergamot Tomurcuk (Sensör Opt.)	Bergamot Tomurcuk Çamlıca Filizi	Bergamot Tomurcuk Çamlıca Filizi (Sensör Opt.)	Tüm Çaylar	Tüm Çaylar (Sensör Opt.)
<b>Karar Ağaçları</b>						
Karar Ağacı (4 dallı)	<b>88.1</b>	<b>88.1</b>	74.6	76.2	43.7	42.1
Karar Ağacı (20 dallı)	<b>88.1</b>	<b>88.1</b>	74.6	76.2	41.3	48.4
Karar Ağacı (100 dallı)	<b>88.1</b>	<b>88.1</b>	74.6	76.2	41.3	48.4
Kuvvetlendirilmiş Ağaç	85.7	83.3	76.2	76.2	40.5	46.8
Bağlı Ağaç	<b>88.1</b>	85.7	79.4	82.5	48.4	51.6
Rastgele Alt Örnekleme ile Kuvvetlendirilmiş Ağaç	<b>88.1</b>	85.7	73	74.6	46	45.2
<b>Doğrusal Ayrım Analizi</b>						
Doğrusal Ayrım Analizi	Hatalı	88.1	76.2	81	46	65.9
Alt Uzay Doğrusal Ayrım Analizi	Hatalı	83.3	85.7	<b>90.5</b>	62.7	65.1
<b>Destek Vektör Makineleri</b>						
Doğrusal Destek Vektör Makineleri	90.5	88.1	87.3	<b>92.1</b>	44.4	49.2
Kuadratik Destek Vektör Makineleri	88.1	85.7	82.5	87.3	56.3	54
Kübik Destek Vektör Makineleri	88.1	85.7	87.3	84.1	54.8	56.3
Basit Gauss Destek Vektör Makineleri	54.8	85.7	55.6	68.3	31.7	40.5
Normal Gauss Destek Vektör Makineleri	88.1	78.6	87.3	87.3	54.0	52.4
Kaba Gauss Destek Vektör Makineleri	85.7	71.4	69.8	85.7	36.5	46.0
<b>k-En Yakın Komşu</b>						
k-En Yakın Komşu (k=1)	<b>88.1</b>	85.7	82.5	82.5	54	52.4
k-En Yakın Komşu (k=10)	76.2	<b>88.1</b>	73	84.1	44.4	50.8
k-En Yakın Komşu (k=100)	47.6	47.6	31.7	31.4	20.6	27
Kosinüs k En Yakın Komşu	83.3	83.3	63.5	74.6	37.3	49.2
Kübik k En Yakın Komşu	85.7	83.3	71.4	84.1	43.7	53.2
Alt Uzay k En Yakın Komşu	85.7	85.7	81	81	51.6	49.2
Ağırlıklı k En Yakın Komşu	<b>88.1</b>	85.7	81	79.4	53.2	54


Yapılan çalışmada ayrıca algoritmaların işlem süreleride incelenmiştir. Yapılan bu incelemede çeşitli sınıflandırma algoritmalarının farklı çalışma yapılarına sahip olmalarına rağmen yaklaşık olarak aynı değerleri vermektedir. Tablo13'te sınıflandırma algoritmalarının çalışma sürelerine ilişkin bilgiler ve en yüksek sınıflandırma doğrulukları birarada verilmiştir.

Tablo 13. En yüksek sınıflandırma başarıları ve işlem süreleri

Sınıflandırma Algoritması	En Yüksek Sınıflandırma Başarısı (%)	Sınıflandırma Algoritmasının İşlem Süreleri (sn)
Karar Ağacı (4 dallı)	54.8	2.6212
Karar Ağacı (20 dallı)	50	2.6468
Karar Ağacı (100 dallı)	50	<b>2.5822</b>
Kuvvetlendirilmiş Ağaç	54.0	3.6527
Bağlı Ağaç	57.1	2.8119
Rastgele Alt Örnekleme ile Kuvvetlendirilmiş Ağaç	50.8	4.6328
Doğrusal Ayrım Analizi	65.9	2.6433
Alt Uzay Doğrusal Ayrım Analizi	<b>70.6</b>	2.8744
Doğrusal Destek Vektör Makineleri	54	2.8325
Kuadratik Destek Vektör Makineleri	61.9	2.8279
Kübik Destek Vektör Makineleri	57.9	2.8601
Basit Gauss Destek Vektör Makineleri	41.3	2.8959
Normal Gauss Destek Vektör Makineleri	57.1	2.8451
Kaba Gauss Destek Vektör Makineleri	44.4	2.8874
k-En Yakın Komşu (k=1)	56.3	2.7675
k-En Yakın Komşu (k=10)	46	2.7777
k-En Yakın Komşu (k=100)	28.6	2.8073
Kosinüs k En Yakın Komşu	49.2	2.812
Kübik k En Yakın Komşu	48.4	2.7572
Alt Uzay k En Yakın Komşu	69.2	3.0731
Ağırlıklı k En Yakın Komşu	53.2	2.7769



Normalizasyon işleminin sınıflandırma başarısına etkisinin incelendiği bu çalışmada, elde edilen en yüksek başarı sonuçlarına ilişkin grafik Şekil 45'te de gösterildiği gibi olmuştur.



Şekil 45. Normalizasyonun sınıflandırma başarısına etkisi

Şekil 45'te gösterilen grafikte 6 adet farklı çayın karar ağaçları, doğrusal ayırım analizi, destek vektör makineleri ve k-en yakın komşu algoritmaları kullanılarak sınıflandırılmasına ilişkin en yüksek başarı sonuçları verilmiştir. En yüksek başarı sonuçları ise normalize edilmiş verilere ait sınıflandırma doğrulukları ve normalize edilmemiş verilere ait sınıflandırma doğrulukları olarak ayrı sütunlarda gösterilmiştir.

#### 4. SONUÇLAR VE ÖNERİLER

Yüksek lisans çalışması olarak hazırlanan bu tezde, adım adım yapılan işlemler ve elde edilen sonuçlar incelendiğinde; çay verilerinin kokularından elektronik burun kullanarak farklı çayları kokularından ayırt etmen işleminin oldukça zor olduğu anlaşılmıştır.

En uygun özniteliklerin ve en uygun sınıflandırıcının bulunması için çıkarılan tüm öznitelikler ve denenen tüm algoritmalar, başarının uygun öznitelik ve de sınıflandırma algoritması seçmekle mümkün olacağını göstermiştir.

Kullanılan özniteliklere ek olarak, alt örnekleme yönteminin de sınıflandırma üzerine etkisi incelenmiştir. Farklı türde nesnelere yaydığı koku türlerinde iyi sonuçlar veren bu alt örnekleme yöntemi ile öznitelik çıkarma işlemi, demlenmiş çaydan yayılan UOB ile elde edilen sayısal verilere uygulandığında, sınıflandırma başarısının demlenmiş siyah çay için uygun olmadığı sonucuna varılmıştır. Bu bağlamda en yüksek sınıflandırma başarısını, tüm öznitelikler incelendiğinde, verilere ait grafiklerde yükselme ve alçalma zamanlarına ait türevlerin, tüm deney süresince elde edilen işaretlerin integrallerinin, maksimum ve minimum noktalarının değerlerinin belirlediği sonucuna varılmıştır.

Sınıflandırma algoritmaları, elektronik burun uygulamalarında çeşitli nesnelere ait kokuların ayırt edilmesinde önemli bir yere sahiptir. Ancak kokuların ayırt edilmesine ilişkin en yüksek başarıyı sağlayacak algoritma kesin olarak belirli değildir. Bu nedenle en yüksek sınıflandırma başarısını verebilecek sınıflandırma algoritmaları, bu data seti üzerinde denenmiştir. Kullanılan algoritmalar içerisinde % 70.9 ile çay sınıflandırmasına en uygun algoritma Alt Uzay Doğrusal Ayrım Analizi olmuştur. Buna en yakın en yüksek sınıflandırma başarı oranını ise k-En Yakın Komşu algoritması vermiştir.

Normalizasyon işleminin etkisinin de incelendiği bu çalışmada, çay verileri üzerinde normalizasyonun pozitif etki sağladığı görülmüştür. Normalizasyon uygulanmamış özniteliklere ait sınıflandırma başarıları daha düşükken, normalizasyon uygulanmış özniteliklerin daha yüksek başarı sonuçlarına ulaştığı sonucuna varılmıştır. Bunun sebebinin ise sayısal verilerde normalizasyonun amacına uygun olarak verilerin sınıflandırmaya daha uygun hale getirilmesinden kaynaklanmaktadır.

Bu çalışmada sınıflandırma başarıları incelendiğinde sınıflandırma başarısı çok fazla yükselmemiştir. Bunun sebebinin çay gibi tek türe ait kokuların UOB'lerinin birbirine çok

benzemesidir. Ancak yapılan alıřmalarda buna raėmen % 70.2 gibi bir sonu elde edilebilmiřtir.

Kokularının daha ayırt edilebileceėi dūřnūlen ayların ikili ve ūlū olarak sınıflandırması yapılmıřtır. Buna baėlı olarak ortaya ıkan sonularda 2,3 ve 4. sınıfa ait ay kokularının birbirine ok yakın ıktıėı sonucuna varılmıřtır. 1,5 ve 6. sınıfa ait aylarda ise sınıflandırma yapılmıř ve bařarı yūzdelerinin % 92.1'e kadar yūkseldiėi gōrūlmūřtur.

Sensōrlerin optimizasyonunun da incelendiėi bu alıřmada, gōrsel olarak optimize edilen sensōrlerin bařarıyı daha da artırdıėı gōrūlmūřtur.



## 5. KAYNAKLAR

1. Ouellette, J., Electronic Noses Sniff Out New Markets, Indust. Physic, 5 (1999) 26-29.
2. Öztürk, Z., Z., Yeni Bir Bilim Dalı: Koku Ölçümü, Gyte E-bülten, Sayı 9, 2008.
3. Chan, C., C., Ozkaynak, H., Spengler, J. D. ve Sheldon, L., Driver Exposure to Volatile Organic Compounds, CO, Ozone, and NO<sub>2</sub> Under Different Driving Conditions, Environmental Science & Technology, 25, 5 (1991) 964-972.
4. Branca, A., Simonian, P., Ferrante, M., Novas, E. ve Negri, R. M., Electronic Nose Based Discrimination of a Perfumery Compound in A Fragrance, Sensors and Actuators B: Chemical, 92, 1 (2003) 222-227.
5. Haeringer, D., & Goschnick, J. (2008). Characterization of smelling contaminations on textiles using a gradient microarray as an electronic nose. Sensors and Actuators B: Chemical, 132(2), 644-649.
6. De Vito, S., Di Francia, G., Piga, M. ve Martinotto, L., Performance Analysis of E-Noseon-Field Calibration for City Air Pollution Quantitative Monitoring, IEEE Sensors, Ekim 2008, Lecce, Italy, Proceedings: 427-429.
7. Siyang, S., Wongchoosuk, C. ve Kerdcharoen, T., Diabetes Diagnosis by Direct Measurement from Urine Odor Using Electronic Nose, Biomedical Engineering International Conference (BMEiCON), Aralık 2012, Ubon Ratchathani, Thailand, Proceedings: 1-4.
8. Roy, R., B., Chattopadhyay, P., Tudu, B., Bhattacharyya, N. ve Bandyopadhyay, R., Artificial Flavor Perception of Black Tea Using Fusion of Electronic Nose and Tongue Response: A Bayesian Statistical Approach, Journal of Food Engineering, 142 (2014) 87-93.
9. Tozlu, B., Elektronik Burunla Çay Fermantasyonu Denetimi, Dokrora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon, 2014.
10. Roy, R., B., Tudu, B., Shaw, L., Jana, A., Bhattacharyya, N. ve Bandyopadhyay, R., Instrumental Testing of Tea by Combining the Responses of Electronic Nose and Tongue, Journal of Food Engineering, 110, 3 (2012) 356-363.
11. Saha, P., Ghorai, S., Tudu, B., Bandyopadhyay, R. ve Bhattacharyya, N., Multi-Class Support Vector Machine for Quality Estimation of Black Tea Using Electronic Nose, IEEE Sixth International Conference on Sensing Technology (ICST), Aralık 2012, Kolkata, India, Proceedings: 571-576.

12. Sharma, P., Ghosh, A., Tudu, B., Sabhapondit, S., Baruah, B., D., Tamuly, P. ve Bandyopadhyay, R., Monitoring the Fermentation Process of Black Tea Using QCM Sensor Based Electronic Nose, Sensors and Actuators B: Chemical, 219 (2015) 146-157.
13. Das, A., Ghosh, T., K., Ghosh, A. ve Ray, H., An Embedded Electronic Nose for Identification of Aroma Index for Different Tea Aroma Chemicals, IEEE Sixth International Conference on Sensing Technology (ICST), Aralık 2012, Kolkata, India, Proceedings: 577-582.
14. Ghosh, S., Bhattacharyya, N., Tudu, B. ve Bandyopadhyay, R., Electronic Nose for On-Line Quality Evaluation of Black Tea Using Incremental SOM Techniques, IEEE 2nd International Symposium on Physics and Technology of Sensors (ISPTS), Mart 2015, Pune, India, Proceedings: 273-277.
15. Liu, H., Luo, D., Li, F. ve Xie, G., Quality Evaluation for Anxi Tieguanyin Tea Based on Electronic Nose and PCALDA Method, IEEE International Conference on Information Science and Cloud Computing Companion (ISCC-C), Aralık 2013, Guangzhou, China, Proceedings: 543-549.
16. Mamlouk, A., M., Quantfying Olfactory Perception, Diploma Thesis, California Institute of Technology, California, 2002.
17. Henning, H., Der Geruch, Barth, Leipzig, 1916.
18. Bhattacharyya, N., Metla, A., Bandyopadhyay, R., Tudu, B. ve Jana, A., Incremental PNN Classifier for a Versatile Electronic Nose, 3rd International Conference on Sensing Technology, Aralık 2008, Tainan, Taiwan, Proceedings: 242-247.
19. Zadeh, L., A., The Concept of Linguistic Variable and Its Application to Approximate Reasoning, Journal of Information Sciences, 8 (1975) 199-249.
20. <https://mehmetacoskun.wordpress.com/2011/11/23/koku-bilimine-dogru/>. 30 Ocak 2018.
21. <https://www.slideshare.net/aakashjain2025/e-nose-47338046> E-Nose. 23 Kasım 2017.
22. Pearce, T., C., Schiffman, S., S., Nagle, H., T. ve Gardner, J. W., Handbook of Machine Olfaction: Electronic Nose Technology, John Wiley & Sons, 2006.
23. <http://www.figaro.co.jp/en/img/development/handoutai/shikumi.gif>. 28 Kasım 2017.
24. Eggins, B., R., Chemical Sensors and Biosensors, John Wiley & Sons, 2008.
25. Valoski, M., P., Instruments for Gas Analysis at Mine Fires/Explosions, SME Annual Meeting, Mart 2010, Phoenix, USA, Proceedings: 10-039.

26. Mani, G., K., ve Rayappan, J., B., B., A Highly Selective Room Temperature Ammonia Sensor Using Spray Deposited Zinc Oxide Thin Film, Sensors and Actuators B: Chemical, 183 (2013) 459-466.
27. Dai, J., Xie, X. ve Zhang, X., C., Detection of Broadband Terahertz Waves with A Laser-Induced Plasma in Gases, Physical Review Letters, 97, 10 (2006) 103903.
28. Agbor, N., E., Petty, M., C. ve Monkman, A., P., Polyaniline Thin Films for Gas Sensing, Sensors and Actuators B: Chemical, 28, 3 (1995) 173-179.
29. El-Sherif, M., A., Yuan, J. ve MacDiarmid, A., Fiber Optic Sensors and Smart Fabrics, Journal of Intelligent Material Systems and Structures, 11, 5 (2000) 407-414.
30. Wenzel, S., W. ve White, R., M., A Multisensor Employing an Ultrasonic Lamb-Wave Oscillator, IEEE Trans. Electron Devices, 35 (1988) 735-743.
31. Tekbıyık, P., Nefes Kokusundan Diabet Tanısı İçin QCM Tabanlı Sistem Tasarımı, Yüksek Lisans Tezi, Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Kütahya, 2007.
32. Lundström, I., Hydrogen Sensitive MOS-structures: Part 1: Principles and Applications, Sensors and Actuators, 1 (1981) 403-426.
33. Grassi, M., Lombardi, A., Ferragina, V., Malcovati, P., Capone, S., Francioso, L. ve Baschirotto, A., Gas Sensor Interface Circuit Based on Calibration Free Novel Frequency Measurement Approach with 16-Bit Digital Output, IEEE Sensors, Ekim 2006, Daejeon, Korea, Proceedings: 220-223.
34. Chiba, A., Development of the TGS Gas Sensor, Chemical Sensor Technology, 4 (1992) 1-18.
35. Sundic, T., Marco, S., Samitier, J. ve Wide, P., Electronic Tongue and Electronic Nose Data Fusion in Classification with Neural Networks and Fuzzy Logic Based Models, Instrumentation and Measurement Technology Conference, Mayıs 2000, Baltimore, USA, Vol 3, Proceedings: 1474-1479.
36. 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.
37. Arshak, K., Moore, E., Lyons, G., M., Harris, J. ve Clifford, S., A Review of Gas Sensors Employed in Electronic Nose Applications, Sensor Review, 24, 2 (2004) 181-198.
38. Ölmez, T. ve Dokur, Z., Uzman Sistemlerde Örüntü Tanıma, İstanbul Teknik Üniversitesi Rektörlüğü, İstanbul, 2009.
39. Gutierrez-Osuna, R., Introduction to Pattern Analysis. Texas A&M University, LECTURE 10: Linear Discriminant Analysis,

40. Nabiyev, V., V., Yapay Zeka (Problemler, Yöntemler, Algoritmalar), İkinci Baskı, Seçkin Yayıncılık, Ankara, 2005.
41. Günal, S., Örüntü Tanıma Uygulamalarında Altuzay Analiziyle Öznitelik Seçimi ve Sınıflandırma, Doktora Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2008.
42. Williams, A., L., Prediction of Odor Pleasantness Using Electronic Nose Technology and Artificial Neural Networks, Doctoral Dissertation, The Pennsylvania State University, The Graduate School Collage of Engineering, Pennsylvania, 2006.
43. Bishop, C., Neural Networks for Pattern Recognition, Second Edition, Oxford University Press, Oxford, 1995.
44. Brahim-Belhouari, S. ve Bermak, A., Gas Identification Using Density Models, Pattern Recognition Letters, 26, 6 (2005) 699-706.
45. 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.
46. Cortes, C. ve Vapnik, V., Support-Vector Networks, Machine Learning, 20, 3 (1995) 273-297.
47. Kavzoğlu, T. ve Çölkesen, İ., Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi, Harita Dergisi, 144, 7 (2010) 73-82.
48. Osuna, E., Freund, R. ve Girosit, F., Training Support Vector Machines: An Application to Face Detection, IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Haziran 1997, San Juan, USA, Proceedings: 130-136.
49. Martinez, M., ve Kak, A., C., PCA versus LDA, IEEE Transactions on Pattern Analysis and Machine Intelligence, 23, 2 (2001) 228-233.
50. <https://stats.stackexchange.com/questions/252616/why-is-there-only-one-discriminant-axis-when-doing-linear-discriminant-analysis> Linear Discriminant Analysis on Two Classes. 11 Aralık 2017.
51. <http://www.saedsayad.com/lda.htm> Linear Discriminant Analysis. 11 Aralık 2017.
52. Cover, T., M. ve Hart, P., E., Nearest Neighbor Pattern Classification, IEEE Transactions on Information Theory, 13, 1 (1967) 21-27.
53. Keller, J., M., Gray, M., R. ve Givens, J., A., A Fuzzy K-Nearest Neighbor Algorithm, IEEE Transactions on Systems, Man and Cybernetics, SMC- 15, 4 (1985) 580-585.

54. Bhatia, N. ve Vandana, Survey of Nearest Neighbor Techniques, International Journal of Computer Science and Information Security, 8, 2 (2010) 302-305 (2010).
55. Liu, H. and Zhang, S., Noisy Data Elimination Using Mutual K-Nearest Neighbor for Classification Mining, Journal of Systems and Software, 85, 5 (2012) 1067-1074.
56. Shmueli, G., Patel, N., R. ve Bruce, P., C., Data Mining: for Business Intelligence, John Wiley & Sons, New Jersey, 2010.
57. <http://www.coxdocs.org/doku.php?id=perseus:user:activities:matrixprocessing:learning:classificationparameteroptimization> Classification Parameter Optimization. 16 Aralık 2017.
58. Su, B., P., Chunwang, M., Sun, Y., Y. ve Liu, K., Clustering Ensemble Method Based DILCA Distance, Machine Learning and Cybernetics (ICMLC), 2013 International Conference on, Temmuz 2013, Tianjin, Vol I, Proceedings: 29-34.
59. Safavian, S., R. ve Landgrebe, D., A Survey of Decision Tree Classifier Methodology, IEEE Transactions on Systems Man and Cybernetics, 21 (1991), 660-674.
60. Quinlan J., R., C4.5: Programs for Machine Learning, Morgan Kaufmann Publishers Inc, San Francisco, CA, 1993.
61. Kavzođlu, T. ve ölkesen, İ., Karar Ağaçları ile Uydu Görüntülerinin Sınıflandırılması, Harita Teknolojileri Elektronik Dergisi, 2, 1 (2010) 36-45.
62. Quinlan J., R., C4.5: Programs for Machine Learning, Morgan Kaufmann Publishers Inc, San Francisco, CA, 1993.
63. Breiman, L., Friedman J., H., Olshen, R., A. ve Stone, C., J., Classification and Regression Trees (Wadsworth Statistics/Probability), International Group, Belmonth, CA, USA, 1984.
64. Dietterich, T., G., Ensemble Learning, The Handbook of Brain Theory and Neural Networks, 2, 110-125, Oregon, 2002.
65. Onan, A. ve Korukođlu, S., Ensemble Methods for Opinion Mining, 23th Signal Processing and Communications Applications Conference (SIU), Mayıs 2015, Malatya, Bildiriler Kitabı: 212-215.
66. Rokach, L., Ensemble-Based Classifiers, Artificial Intelligence Review, 33, 1-2 (2010), 1-39.
67. Breiman, L., Bagging Predictors, Machine Learning, 24, 2 (1996) 123- 140.
68. Panov, P. ve Dzeroski, S., Combining Bagging and Random Subspaces to Create Better Ensembles, Lecture Notes in Computer Science, 4723 (2007) 118-129.
69. Özdađođlu, A., Normalizasyon Yöntemlerinin Çok Ölçütlü Karar Verme Sürecine Etkisi–Moora Yöntemi İncelemesi, Ege Academic Review, 14, 2 (2014) 283-294.



70. Z. Filiz, "Güvenilirlik Çözümlemesi, Temel Bileşenler ve Faktör Çözümlemesi", Anadolu Üniversitesi Bilim ve Teknoloji Dergisi, Cilt.4, No.2, s. 211–222, 2003.
71. Çilli, M., "İnsan Hareketlerinin Modellenmesi ve Benzeşiminde Temel Bileşenler Analizi Yönteminin Kullanılması", Doktora Tezi, Hacettepe Üniversitesi Sağlık Bilimleri Enstitüsü, 240 s, 2007.
72. Sütçüler, E., "Gerçek Zamanlı Video Görüntülerinden Yüz Bulma ve Tanıma Sistemi", Yüksek Lisans tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, 90 s, 2006.
73. Yazar, I., Yavuz, H.S., ve Çay, M. A., "Temel Bileşen Analizi Yönteminin ve Bazı Klasik ve Robust Uyarlamalarının Yüz Tanıma Uygulamaları." (2017): 49-63.



## ÖZGEÇMİŞ

Yavuz KABLAN, 1990 Şalpazarı doğumludur. İlkokulu ve ortaokulu Kaledibi İlköğretim Okulu'nda, liseyi Tevfik Serdar Anadolu Lisesi'nde tamamlamıştır. Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nden 2014 yılında mezun olmuştur. 2015-2016 eğitim-öğretim yılının güz döneminde Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans programına katılmıştır. 2017 yılı mayıs ayında Avrasya Üniversitesi Elektrik-Elektronik Mühendisliği'nde Araştırma Görevlisi olarak çalışmaya başlamıştır. Halen Avrasya Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaktadır. Yabancı dil olarak İngilizce bilmektedir.