KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KARMA SENSÖR YAPILI ELEKTRONİK BURUN İLE AKCİĞER KANSERİ TESPİTİ

DOKTORA TEZİ

Ümit ÖZSANDIKCIOĞLU

EKİM 2023
TRABZON

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KARMA SENSÖR YAPILI ELEKTRONİK BURUN İLE AKCİĞER KANSERİ TESPİTİ

Ümit ÖZSANDIKCIOĞLU

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 13 / 09 / 2023
Tezin Savunma Tarihi : 10 / 10/ 2023

Tez Danışmanı : Prof. Dr. Ayten ATASOY

Trabzon 2023

ÖNSÖZ

"Karma Sensör Yapılı Elektronik Burun İle Akciğer Kanseri Tespiti" isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı, Doktora Programı'nda hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve bilim insanı olma yolundaki ilk adımlarımı atarken kıymetli bilgileriyle ve tecrübesiyle yolumu aydınlatan danışman hocam Sayın Prof. Dr. Ayten ATASOY'a teşekkürü bir borç bilirim. Ayrıca, yapıcı eleştirileri ve önerileri ile tezime büyük katkıları bulunan saygıdeğer hocalarım Sayın Prof. Dr. Vasıf NABIYEV'e ve Sayın Doç. Dr. Yusuf SEVİM'e, teşekkür ederim.

Tez çalışması sürecinde bana desteklerini esirgemeyen Elektrik Elektronik Mühendisliği Bölümü'ndeki tüm değerli hocalarıma ve araştırma görevlisi arkadaşlarıma teşekkürlerimi sunarım.

Bu çalışmayı 215E380 numaralı proje kapsamında destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na (TÜBİTAK) ve bu tezde kullanılan Kuvars Kristal Mikrobalans sensörlerin tedariği konusundaki desteklerinden dolayı TÜBİTAK Marmara Araştırma Merkezi Malzeme Bilimleri Enstitüsüne teşekkür ederim.

Son olarak, doğduğum günden beri elimi hiç bırakmayan, hayatım boyunca aldığım tüm kararlarda bilgi ve tecrübelerinden faydalandığım ve her kararımda arkamda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan annem Zühre ÖZSANDIKCIOĞLU ve babam Zeki ÖZSANDIKCIOĞLU'na ve ablam Nejla ÖZSANDIKCIOĞLU'na teşekkür eder, minnettarlığımı sunarım.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Ümit ÖZSANDIKCIOĞLU

Trabzon 2023

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum "Karma Sensör Yapılı Elektronik Burun İle Akciğer Kanseri Tespiti" başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Ayten ATASOY'in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 10/10/2023

Ümit ÖZSANDIKCIOĞLU

İÇİNDEKİLER

Sayfa No

ÖNSÖZ III
TEZ ETİK BEYANNAMESİ IV
İÇİNDEKİLER V
ÖZET VII
SUMMARY VIII
ŞEKİLLER DİZİNİ IX
TABLOLAR DİZİNİ XI
SEMBOLLER VE KISALTMALAR DİZİNİ XII
1. GENEL BİLGİLER 1
1.1. Akciğer Kanseri Nedir? 2
1.2. Akciğer Kanser ine Neden Olan Mutasyonlar 3
1.3. Akciğer Kanseri Çeşitleri 5
1.3.1. Küçük Hücreli Dışı Akciğer Kanseri 5
1.3.2. Küçük Hücreli Akciğer Kanseri 5
1.4. Akciğer Kanserine İlişkin Risk Faktörleri 5
1.5. Akciğer Kanseri Belirtileri 6
1.6. Tanı Yöntemleri 7
1.7. Evreleme 8
1.8. Tedavi 9
1.9. Çalışmanın Motivasyonu 10
1.10. Önerilen Yaklaşım 12
1.11. Elektronik Burun 16
1.11.1. Algılayıcı Birim 18
1.11.2. Dönüştürücü Birim 21
1.11.3. Elektronik Birim 21
1.11.4. Örüntü Tanıma Birimi 22
1.11.5. Temel Bileşen Analizi 23
1.11.6. Doğrusal Ayrıştırma Analizi 25
1.11.7. Karar Ağaçları 28
1.11.8. Destek Vektör Makinaları (DVM) 31

1.11.9. Rastgele Orman 36
1.11.10. Bulanık Mantık ve Bulanıklık Kavramı 37
1.11.11. Meta-sezgisel Yöntemler 43
1.11.12. Genetik Algoritma 44
1.11.13. Parçacık Sürü Optimizasyonu 46
1.11.14. Benzetimli Tavlama 47
1.11.15. İstilacı Yabani Ot Optimizasyon Algoritması 48
1.11.16. Yapay Ekosistem Optimizasyonu 50
1.11.17. k-Kat Çapraz Doğrulama ve Başarı Ölçümleri 53
1.11.18. Literatürde Bulunan Çalışmalar 53
2. YAPILAN ÇALIŞMALAR 58
2.1. Elektronik Burun Deney Düzeneği 58
2.1.1. Kuru Hava 59
2.1.2. Teflon Borular 59
2.1.3. Tedlar Torba 59
2.1.4. Vakum Pompası 60
2.1.5. Solenoid Valf 61
2.1.6. Kontrol Kartı 61
2.1.7. QCM Sensörler ve QCM sensör hücresi 63
2.1.8. MOY Sensörler ve MOY Sensör haznesi 64
2.1.9. MOY (Metal Oksit Yarıiletken) Sensör haznesinin ve Bu Sensörlere Bağlı Dirençlerin Yerleştirileceği kartların Oluşturulması 66
2.1.10. Gerçekleştirilen E-burun Devresinin Çalışması 68
2.2. Nefes Örneklerinin Toplanması 69
2.3. Veri Analizi ve Öznitelik Çıkarma 72
3. BULGULAR VE TARTIŞMA 80
3.1.1. Üç Sınıflı Veri sınıflandırma 83
3.1.2. BMY sınıflandırma sonuçları 90
4. SONUÇLAR 94
5. ÖNERİLER 95
6. KAYNAKLAR 96
ÖZGEÇMİŞ

ÖZET

Doktora Tezi

KARMA SENSÖR YAPILI ELEKTRONİK BURUN İLE AKCİĞER KANSERİ TESPİTİ

Ümit ÖZSANDIKCIOĞLU

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalında
Danışman: Prof. Dr. Ayten ATASOY
2023, 104 Sayfa

Akciğerler solunum sisteminin en önemli organlarıdır. Nefeste bulunan, genellikle kan orjinli ve vücuttaki farklı işlemleri gözetlememize imkan sağlayan uçucu organik bileşikler kan yoluyla akciğerlere taşınmakta ve solunum yoluyla dışarı atılmaktadır. Hiç şüphesiz nefesten gelen bu uçucu organik bileşikler akciğer kanseri ile ilgili rahatsızlıkların erken tespitinde bizlere önemli ipuçları verebilecek niteliktedir. Bu çalışma kapsamında 8 adet Metal Oksit Yarıiletken ve 14 adet Kuvars Kristal Mikrobalans gaz sensörlerinin kullanılmasıyla karma sensör tabanlı bir elektronik burun devresi geliştirilmiştir. Çalışmaya akciğer kanseri hastası olan 60 gönüllü, sigara kullanmayan 20 sağlıklı gönüllü ve sigara kullanan 20 sağlıklı gönüllü olmak üzere toplam 100 gönüllü katılmıştır. Çalışma boyunca gönüllülerden alınan nefes örnekleriyle 338 adet deney gerçekleştirilmiştir. Bu çalışmada veri boyutu azaltma için Temel Bileşen Analizi ve Doğrusal Ayrıştırma Analizi algoritmaları, veri sınıflandırma için ise Karar Ağaçları, farklı çekirdek fonksiyonlarının kullanıldığı Destek Vektör Makinası, k-En Yakın Komşu, Rastgele Orman ve Bulanık Mantık Yöntemi algoritmaları kullanılmıştır. Yapılan deneyler sonucunda elde edilen veriler hem iki sınıflı (akciğer kanseri- sağlıklı) hem de üç sınıflı (akciğer kanseri- sigara kullanan sağlıklı- sigara kullanmayan sağlıklı) verileri içerecek şekilde sınıflandırılmıştır İki sınıflı veri sınıflandırma sonucunda en yüksek sınıflandırıma başarısı lineer çekirdek fonksiyonu kullanılan destek vektör makinası algoritmasıyla %95,36 olarak elde edilmiştir. Üç sınıflı veri sınıflandırma sonucunda ise en yüksek sınıflandırma başarısı bulanık mantık yönteminin kullanılmasıyla %97.93 olarak elde edilmiştir.

Anahtar Kelimeler: Biyomedikal sinyal işleme, nefes analizi, elektronik burun, akciğer kanseri tespiti

SUMMARY

PhD. Thesis

HYBRID SENSOR BASED E-NOSE FOR LUNG CANCER DIAGNOSIS

Ümit ÖZSANDIKCIOĞLU

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Enginnering Graduate Program
Supervisor: Prof. Dr. Ayten ATASOY
2023, 104 Pages

Lungs are the most important organs of the respiratory system. The volatile organic compounds found in the breath, which are usually blood-originated and enable us to observe different processes in the body, are carried to the lungs through the blood and then expelled by respiration. Undoubtedly, these volatile organic compounds from the breath can give us important clues in the early detection of lung cancer-related disorders.In this study, a mixed sensor based electronic nose circuit was developed by using 8 Metal Oxide Semiconductor and 14 Quartz Crystal Microbalance gas sensors. A total of 100 volunteers, including 60 volunteers with lung cancer, 20 healthy volunteers who do not smoke, and 20 healthy volunteers who smoke, participated in the study.A total of 338 experiments were carried out with breath samples taken from volunteers throughout the study. In this study, Principal Component Analysis and Linear Decomposition Analysis algorithms were used for data size reduction, Decision Trees, Support Vector Machine using different kernel functions, k-Nearest Neighbor, Random Forest and Fuzzy Logic Method algorithms were used for data classification. The data obtained as a result of the experiments were classified to include both two-class (lung cancer- healthy) and three-class (lung cancer-smoker healthy-non-smoker healthy) data and the success values of the algorithms used were determined. As a result of two-class data classification, the highest classification success was achieved as 95.36% with the support vector machine algorithm using the linear kernel function. As a result of the three-class data classification, the highest classification success was achieved as 97.93% by using the fuzzy logic method.

Key Words: Biomedical signal processing, breath analysis, electronic nose, lung cancer diagnosis

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. Solunum sistemine ait organlar ve bileşenleri. 1
Şekil 2. Akciğerlerin genel yapısı. 2
Şekil 3. Metastatik akciğer kanserinin organlara yayılımı. 3
Şekil 4. 2020 yılı için tahmini olarak teşhis koyulacak (a) kanser vakalarının dağılım, (b) kanser nedenli ölümlerin dağılımı (Siegel vd.,2020) 11
Şekil 5. Küçük hücreli dışı akciğer kanseri 5-yıllık sağkalım oranları 11
Şekil 6. Biyolojik burun ve e-burun ilişkisi 17
Şekil 7. Çalışmada kullanılan işaret işleme aşamaları 22
Şekil 8. DDA yöntemine ilişkin görsel 26
Şekil 9. Karar Ağaçları Genel Yapısı 29
Şekil 10. a) İki sınıflı bir problem için hiper-düzlemler, (b) Optimum hiper-düzlem ve 32
Şekil 11. Doğrusal olarak düzlemin belirlenmesi. 33
Şekil 12. Kernel fonksiyonu ile verinin daha yüksek bir boyuta dönüştürülmesi 35
Şekil 13. Rastgele orman yönteminin genel yapısı 36
Şekil 14. Yeşil, siyah ve mavi bulanık renk kümeleri 39
Şekil 15. Bulanık sistemlerin genel yapısı 39
Şekil 16. Gaus üyelik fonksiyonu genel yapısı 40
Şekil 17. Üçgen üyelik fonksiyonu genel yapısı 40
Şekil 18. Çan üyelik fonksiyonu genel yapısı 40
Şekil 19. Yamuk üyelik fonksiyonu genel yapısı 41
Şekil 20. Pi-şekilli üyelik fonksiyonu genel yapısı 41
Şekil 21. Alanların merkezi durulaştırma yöntemi akış diyagramı 42
Şekil 22. Meta-sezgisel algoritmaların sınıflandırılması. 43
Şekil 23. GA' da çaprazlama işlemi 45
Şekil 24. GA' da mutasyon işlemi 45
Şekil 25. YEO' da örnek bir ekosistem 50
Şekil 26. Geliştirilen elektronik burun devresinin blok diyagramı 59
Şekil 27. Çalışmada kullanılan Tedlar torba (a) ve polipropilen başlık detayı (b) 60
Şekil 28. Çalışmada kullanılan vakum pompası 61
Şekil 29. Çalışmada kullanılan solenoid valf ve bağlantıları 61

Şekil 30. Kontrol devresinde kullanılan elektronik devre 62
Şekil 31. Hazırlanan kontrol kartının fotoğrafı 63
Şekil 32. Çalışmada kullanılan (a) KKM sensörlerin yapısı (b) KKM sensör hücresi 63
Şekil 33. MOY gaz sensörlerine ait teknik çizimler (a) TGS8xx serisi (b) TGS2xxx serisi 65
Şekil 34. MOY gaz sensörlerine ilişkin elektriksel eşdeğer devre 66
Şekil 35. Çalışmada kullanılan MOY sensör haznesi 67
Şekil 36. Çalışmada kullanılan MOY ve KKM sensör çeşitleri 67
Şekil 37. Gerçekleştirilen e-burun devresi 68
Şekil 38. Bir deney sonucu oluşan (a) MOY sensör, (b) KKM sensör işaretleri 70
Şekil 39. (a) Hasta gönüllülerin sahip olduğu kanser hücre türüne göre dağılım, (b) Hasta 71
Şekil 40. MOY sensörler için: a) İşlenmemiş Sensör verileri, b) Referans düzeltme ve iletkenlik dönüşümü yapılmış veriler 73
Şekil 41. KKM sensörler için: a) İşlenmemiş Sensör verileri, b) Referans düzeltilmiş sensör verileri 74
Şekil 42. Akciğer kanseri hasta gönüllüye ait (a) MOY, (b) KKM sensör işaretleri 75
Şekil 43. Sigara kullanan sağlıklı gönüllüye gönüllüye ait (a) MOY, (b) KKM sensör 76
Şekil 44. Sigara kullanmayan sağlıklı gönüllüye ait deney sonucu 77
Şekil 45. DDA(MOY+KKM) verisi dağılım grafiği 91
Şekil 46. Optimizasyon algoritması kullanılarak elde edilen çan üyelik fonksiyonları 93

TABLOLAR DİZİNİ

Sayfa No

Tablo 1. Farklı kanser türleri için hasta ve sağlıklı gönüllülerin nefeslerinde en fazla farklılığın olduğu UOB'ler 14
Tablo 2. Nefesteki aldehit seviyeleri..... 16
Tablo 3. E-burun uygulamalarında kullanılan sensörler..... 21
Tablo 4. Devrede kullanılan devre elemanlarının değerleri ve modelleri 62
Tablo 5. Çalışmada kullanılan MOY sensörler ve bu sensörlere ait hedef gazlar..... 64
Tablo 6. Çalışmada kullanılan MOY gaz sensörlerine ait teknik bilgiler..... 66
Tablo 7. Kullanılan MOY tipi sensörlere bağlı olan yük dirençleri 66
Tablo 8. Bir deney süresince valflerin durumları 69
Tablo 9. Çalışmaya katılan gönüllülere ilişkin bilgiler..... 71
Tablo 10. Kullanılan özellikler ve sınıflandırma algoritmaları için sınıflandırma sonuçları..... 82
Tablo 11. İki sınıflı sınıflandırma sonuçlarına ilişkin sınıflandırma detayları 83
Tablo 12. Kullanılan özellikler ve sınıflandırma algoritmaları için sınıflandırma sonuçları..... 84
Tablo 13. MOY-RO Sınıflandırma sonuçları 85
Tablo 14. TBA(MOY)- RO Sınıflandırma sonuçları..... 85
Tablo 15. DAA(MOY)-L-DVM Sınıflandırma sonuçar..... 86
Tablo 16. KKM- RO Sınıflandırma sonuçları 86
Tablo 17. TBA(KKM)-k-EYK Sınıflandırma sonuçları..... 87
Tablo 18. DAA(KKM)- RO Sınıflandırma sonuçları 87
Tablo 19. (MOY+KKM)-Q-DVM Sınıflandırma..... 88
Tablo 20. TBA(MOY+KKM)-RO Sınıflandırma..... 88
Tablo 21. DAA(MOY+KKM)-RO Sınıflandırma sonuçları 89
Tablo 22. TBA(MOY)+TBA(KKM)-k-EYK sınıflandırma sonuçları 89
Tablo 23. DAA(MOY)+DAA(KKM)-LDVM Sınıflandırma sonuçları 90
Tablo 24. BMY ile sınıflandırma için oluşturulan kural tablosu. 92
Tablo 25. BMY ile yapılan sınıflandırma sonuçları 92

SEMBOLLER VE KISALTMALAR DİZİNİ

λ_i : Özdeğerler

Ψ : Parçacık Sürü Optimizasyonu için hızlanma değeri

T_C : Benzetimli Tavlama Optimizasyonu için sıcaklık parametresi

C : Yapay Ekosistem Optimizasyonu için tüketim faktörü

D : Yapay Ekosistem Optimizasyonu için ayrıştırma faktörü

V_C : Metal Oksit Yarıiletken sensör için besleme gerilimi

V_H : Metal Oksit Yarıiletken sensör için ısıtıcı gerilimi

R_L : Metal Oksit Yarıiletken sensör için yük direnci

E-burun : Elektronik Burun

UOB : Uçucu Organik Bileşen

TBA : Temel Bileşen Analizi

DAA : Doğrusal Ayrıştırma Analizi

KA : Karar Ağacı

DVM : Destek Vektör Makinası

k-EYK : k-En Yakın Komşu

RO : Rastgele Orman

BMY : Bulanık Mantık Yöntemi

GA : Genetik Algoritma

PSO : Parçacık Sürü Optimizasyonu

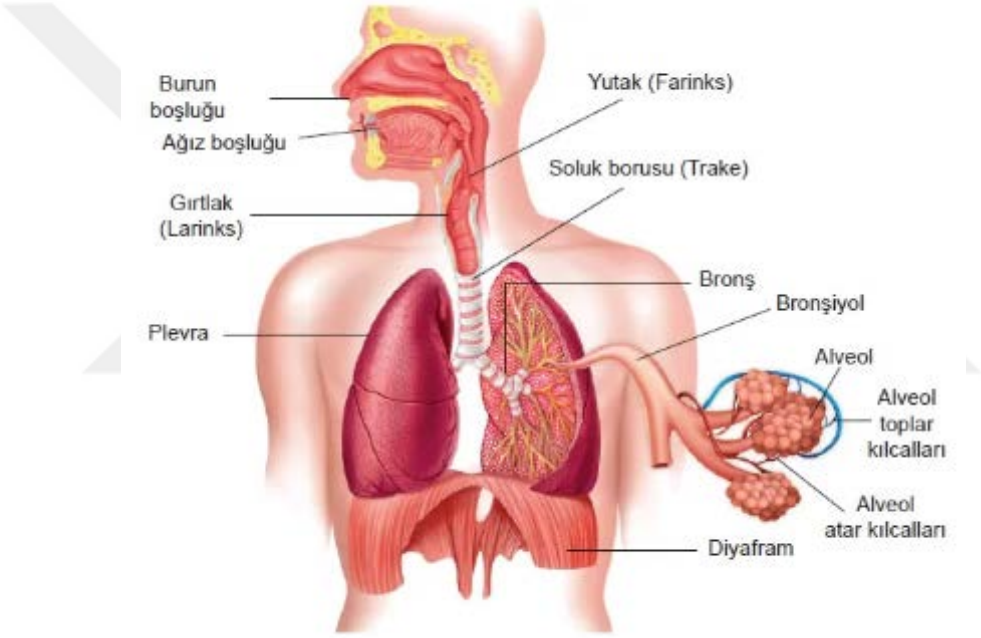
BA : Benzetimli Tavlama

İYO : İstilacı Yabani Ot

YEO : Yapay Ekosistem Optimizasyonu

1. GENEL BİLGİLER

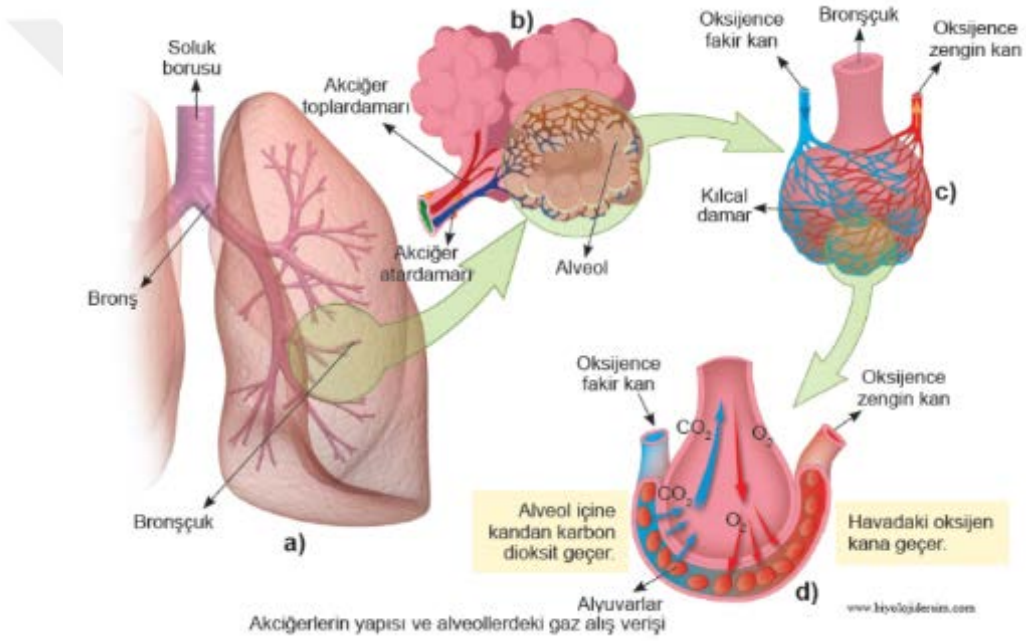
Akciğerler ve solunum sistemi insan vücudunun dış ortamdan gaz alışverişini sağlayan sistemdir. Solunum sistemi yardımıyla vücudun ihtiyaç duyduğu oksijen vücuda alınırken, vücudun çalışması sonucu ortaya çıkan karbondioksit vücut dışına atılır. Akciğerler, soluk borusu, gırtlak, akciğerlere ait bronşlar ve alveoller alt solunum yolunu oluşturmaktadır. Üst solunum yolu ise ağız, burun boşluğu, sinüsler, boğaz ve gırtlaktan oluşmaktadır. Solunum sistemini oluşturan bileşenler Şekil 1' de verilmektedir (URL-1, 2020).



Şekil 1. Solunum sistemine ait organlar ve bileşenleri.

Akciğerler, göğüs boşluğunun içerisine yerleşmiştir ve solunum yolunun son organlarıdır. Alt kısmı, üst kısmına göre bir miktar daha geniş olması nedeniyle koni şeklinde bir görüntüsü mevcuttur. Akciğerlerin alt kısmında diyafram bulunmaktadır. Ön, arka ve yan yüzeyleri ise kaburgalar arasındaki kaslar ile temas halindedir. Kalbin sol tarafta bulunması nedeniyle, akciğerin sağ kısmı sol kısmından daha büyüktür. Sağ akciğer üç bölümden, sol akciğer ise iki bölümden oluşmaktadır. Bu bölümler kendi içerisinde daha küçük bölümlere ayrılmaktadır ve bu küçük bölümleri de oluşturan bölümlere segment denmektedir. Her bir akciğerde on adet segment bulunmaktadır. Soluk borusundan ayrılmış

olan bir adet ana bronş her bir akciğere girmektedir. Bu bronşlar akciğer içerisinde bir ağacın dalları gibi dallanarak daha küçük parçalara ayrılırlar ve son olarak daha küçük parçalar olan bronşçuklara ayrılırlar. Bronşçuklar sonlandıkları yerde yuvarlak ve şişkin keseler halindedirler. Akciğerlerdeki bu keselere alveoller denir. Bronşlardan alveollere kadar olan dallanmış yapı üzüm salkımı görüntüsündedir. Bu dallanma halindeki yapı solunumun gerçekleşeceği yüzey alanını artırmaktır. Akciğerlerin çevresi plevra ismi verilen çift katlı bir zarla kaplıdır. Plevra zarı, katmanları arasında solunum sırasında akciğerlerin hareket edebilmesine olanak sağlayan bir sıvı bulundurmaktadır. Akciğerler ve yapısında bulunan alveollere ilişkin görsel Şekil 2' de verilmektedir (URL-2, 2019).

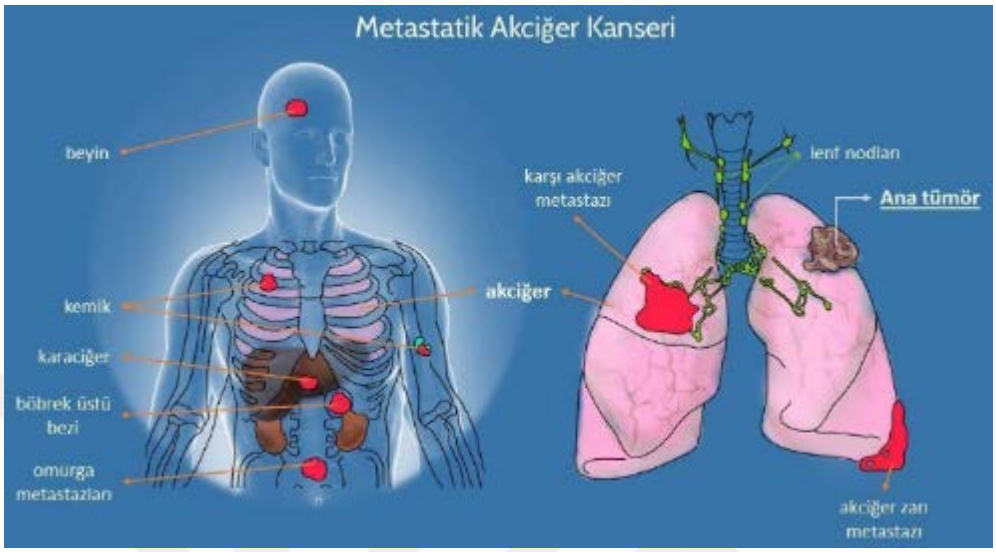


Şekil 2. Akciğerlerin genel yapısı.

1.1. Akciğer Kanseri Nedir?

Akciğerleri oluşturan hücreler tıpkı diğer organlarda olduğu gibi ihtiyaç duyulduğunda bölünmekte ve çoğalmaktadır. Bu bölünme ve çoğalma işlemi akciğerlerin doğal çalışmasını sağlayan gerekli olan bir işlemdir. Ancak, akciğer dokusunda bulunan bu hücrelerin normal şekilde çoğalmaları yerine kontrolsüz şekilde çoğalması sonucu akciğer içerisinde kitle (tümör) oluşur. Akciğerlerde oluşan bu kitle öncelikle bulunduğu ortamda büyür ve ardından ileri aşamalarda çevresinde bulunan dokulara, karaciğer, kemik ve beyin gibi uzak organlara

sirayet eder. Hücrelerin kontrolsüzce çoğalmaları ve farklı doku-organlara yayılmalarına metastaz adı verilir. Akciğer kanserine ait tümör ve metastaz oluşumu Şekil 3' te verilmektedir (URL-3).



Şekil 3. Metastatik akciğer kanserinin organlara yayılımı.

1.2. Akciğer Kanser ine Neden Olan Mutasyonlar

Akciğer kanseri hastalığı sebepli ölümlerin tüm kanser türleri arasında en yüksek sayıya sahip olması araştırmacıların bu hastalık üzerine yaptıkları çalışmaları önemli ölçüde artırmaktadır. Akciğer kanseri nedenli moleküler değişiklikler "driver" mutasyonlar/moleküler değişiklik olarak tanımlanmaktadır. Akciğer kanserinin başlangıcından ve gelişimden sorumlu olan bu driver değişiklikler aşağıdaki gibi verilmektedir.

EFGR (epidermal büyüme faktörü reseptörü) geni 7p12-13 kromozomuna lokalize durumdadır ve hücre membran reseptörleri tirozin kinaz ailesine aittir. Bu mutasyon da EFGR geni üzerinde aktive edici bir mutasyon çeşididir ve tirozin kinaz inhibitörlerinden biri olan gefitinib-erlotinib genlerinin hedef alanıdır (Lynch vd., 2004)(Rosell vd., 2012). EFGR mutasyonu akciğer adenokarsinomu vakalarının yaklaşık olarak %20' sinde görülmektedir (Bozkurtlar & Kaya, 2018). Bu mutasyonun teşhisi Sekanslama veya polimeraz zincir reaksiyonu (PCR) yöntemi kullanılarak tespit edilir.

ALK rearranjmanı, ALK (anaplastik lenfoma kinaz) genini de içeren bazı kromozomal değişiklikler sonucu oluşmaktadır ve akciğer adenokarsinom vakalarının yaklaşık olarak %5' inde görülmektedir. Bu mutasyonun tespit edildiği vakaların çoğu genç ve sigara

kullanmayan ya da hafif sigara içicileridir. Bu mutasyon çeşidinin tespiti için günümüzde altın standart olarak adlandırılan bir yöntem kullanılır. Bu yöntem Floresan in situ hibridazosyon (FİSH) yöntemi yardımıyla break-apart problar kullanılır (Cutz vd., 2014).

ROS1 (proto-onkojen tirozin-protein kinaz 1 ROS) rearranjmanı da tıpkı ALK mutasyonunda olduğu gibi ROS1 genini içeren bir dizi kromozamal değişiklikler sonucu oluşmaktadır. ROS1 tirozin kinaz reseptörlerinden biridir ve insülin reseptör ailesine aittir. Bu mutasyon çeşidi akciğer adenokarsinom vakalarının yaklaşık %1-%2' sinde görülmektedir. Bu mutasyonun teşhisi için henüz altın standart bir yöntem bulunmamaktadır ancak FİSH, PCR testleri ve yeni nesil sekanslama gibi yöntemler kullanılabilir (Mehrad vd., 2017).

RET rearranjmanı tıpkı ALK ve ROS1 gibi RET genini içeren bir dizi kromozomal değişikliği ifade eder. Akciğer adenokarsinom vakalarının yaklaşık olarak yaklaşık %1-%2' sinde görülmektedir ve çoğunlukla sigara kullanmamış hastalarda görülür. Bu mutasyonu teşhis etmek için genellikle FİSH yöntemi kullanılabilir ancak sekanslama ve PCR yöntemi de teşhis için kullanılabilir (Gautschi vd., 2017).

KRAS (Kirsten sıçan sarkomaviral onkogen) mutasyonu akciğer adenokarsinomları vakaları arasında en fazla gözlemlenen mutasyon çeşididir ve oran olarak %20-30' lara kadar çıkmaktadır. KRAS mutasyonu içeren tömörler yapılarında EFGR ve ALK gibi onkojenik değişiklikler içermezler. Bu mutasyonun tespiti için PCR ve sekanslama yöntemi kullanılabilir. KRAS mutasyonuna çoğunlukla sigara kullanan hasta bireylerde rastlanır (Ju vd., 2016).

BRAF (v-Raf murin sarkomu viral onkogen homoloğu B) mutasyonu adenokarsinom vakalarının yaklaşık olarak %5'inde görülür ve bu mutasyon çeşidinin yarısını V600E mutasyonu oluşturmaktadır. BRAF mutasyonunu akciğer tümörlerinde immünhistokimyasal yöntemler kullanılarak tespit edilememektedir. Bu nedenle PCR ya da sekanslama yöntemi kullanılarak BRAF mutasyonu tespit edilebilmektedir (Planchard vd., 2016).

MET (Mezenkimal epitelyal geçiş geni) mutasyonu ve amplifikasyonu, FİSH yöntemi ve yeni nesil sekanslama yöntemleriyle tespit edilebilirken MET mutasyonu ise sekanslama ve PCR yöntemiyle tespit edilebilir. Bu mutasyonlar çoğunlukla ekzon 14 çevresinde bulunmaktadır. MET amplifikasyonu ve MET mutasyonu birbirlerini dışlayan onkojenik farklılıklar değildirler ve aynı hastalarda hem MET amplifikasyonu hem de MET mutasyonu gözlemlenebilir (Rabeau vd., 2017).

ERBB2 (İnsan epidermal büyüme faktörü reseptörü 2) mutasyonu ve amplifikasyonu ERBB2 mutasyonu PCR ve sekanslama yöntemleriyle tespit edilirken, RBB2 amplifikasyonu gümüş bazlı in situ hibridizasyon (SISH) ve FİSH yöntemleriyle tespit edilebilir. Akciğer adenokarsinom vakalarının yaklaşık olarak %10-%20' sinde ERBB2 amplifikasyonu görülmekteyken, ERBB2 mutasyonları akciğer adenokarsinom vakalarının %2-%4' ünde görülmektedir (Kim vd., 2017).

1.3. Akciğer Kanseri Çeşitleri

1.3.1. Küçük Hücreli Dışı Akciğer Kanseri

Bu kanser türü en sık karşılaşılan kanser türüdür ve toplam akciğer kanseri vakalarının yaklaşık 85%' ini oluşturmaktadır. Bu kanser türü de kendi içerisinde üç farklı çeşide sahiptir. Bu türler; yassı hücreli karsinom, büyük hücreli karsinom ve adenokarsinomdur. Her bir kanser türü farklı kanser hücrelerine sahiptir ve bu hücrelerin büyüme ve yayılma şekilleri de birbirlerinden farklıdır. Küçük hücreli dışı akciğer kanserinin daha az rastlanan çeşitlerine ise pleomorfik, karsinoid tümör, tükürük bezi karsinomu ve sınıflandırılmamış karsinom örnek verilebilir (Nooreldeen&Bach, 2021).

1.3.2. Küçük Hücreli Akciğer Kanseri

Bu kanser türü daha az rastlanan bir kanser türüdür ve toplam akciğer kanseri vakalarının yaklaşık olarak 15%' ini oluşturmaktadır. Bu kanser türü kanser hücrelerine ve bu hücrelerin mikroskop altındaki görüntülerine bağlı olarak iki tür içermektedir. Bu türlerden ilki küçük hücreli (yulaf hücreli) akciğer kanseri ikincisi ise kombine tip küçük hücreli akciğer kanseridir (Nooreldeen&Bach, 2021).

1.4. Akciğer Kanserine İlişkin Risk Faktörleri

Tüm hastalıklarda olduğu gibi akciğer kanserine yakalanma olasılığını artıran bazı etkenler vardır. Bu etkenleri aşağıdaki gibi sıralayabiliriz.

Sigara, pipo, nargile ve puro gibi tütün ürünlerinin tüketilmesi, akciğer kanseri hastalığının en önemli risk faktörüdür. Literatürde bulunan çalışmalar incelendiğinde akciğer kanserine yakalanan her on erkek bireyin dokuzunun her on kadın bireyin ise

sekizinin sigara kullanmış veya kullanmakta olduğu belirlenmiştir. Yapılan çalışmalar yine göstermektedir ki içeriğinde düşük katran veya düşük nikotin bulunan sigara tüketilmesi kanser riskini azaltmamaktadır. Bunların yanında günlük fazla sayıda sigara içilmesi ve sigara kullanılan yıl sayısının artması akciğer kanseri hastalığına yakalanma riskini artırdığı belirlenmiştir (Chen vd., 2019).

Sigara dumanına maruz kalmak (Pasif içicilik) de sigara içinde bulunan zararlı bileşenlere maruz kalmakta ve akciğer kanserine yakalanma olasılıkları pasif içici olmayan insanlara göre daha fazla olmaktadır (Wang vd., 2019).

Asbest, arsenik, krom, berilyum, nikel, kurum veya katran gibi kimyasallara maruz kalmak akciğer kanseri hastalığına yakalanma riskini artırmaktadır. Bu gibi kimyasallara maruz kalma süresi ve kimyasalların yoğunluğu akciğer kanseri hastalığına yakalanma olasılığı ile doğru orantılıdır (National Bureau of Statistics of China, 2019).

Radyasyona maruz kalmak akciğer kanserine yakalanma olasılığını artırmaktadır. Radyasyon terapisi, hastanelerde gerçekleştirilen radyasyon içeren görüntüleme testleri, radon gazını solumak ve bu gaza maruz kalmak da akciğer kanserine yakalanma olasılığını artırmaktadır (Kasmann vd. 2020).

Literatürde bulunan çalışmalar göstermektedir ki akciğer kanseri, hava kirliliğinin yüksek olduğu bölgelerde yaşayan insanlar arasında daha yaygın görülmektedir (Guo vd., 2016).

Ailede akciğer kanseri geçmişi bulunması, bu hastalık için risk faktörlerinden biridir. Konuyla ilgili çalışmalar incelendiğinde akrabaları arasında akciğer kanserine yakalanmış bireyler bulunan kişiler, akrabaları arasında bu hastalığa yakalanmamış olan bireylere göre daha fazla akciğer kanserine yakalanmaktadır (Erbaycu, 2020).

1.5. Akciğer Kanseri Belirtileri

Akciğer kanseri genellikle erken evrelerde belirti vermeden ilerler ve asıl belirtileri ileri evrelerde ortaya çıkar. Yapılan çalışmalar sonucunda bu belirtiler aşağıdaki gibi sıralanabilir (Bircan vd., 2005).

- Göğüste ağrı veya acı
- Uzun süren ve zamanla daha da kötüleşen öksürük
- Nefes alıp vermede zorlanma ve hırıltı
- Balgamda kan görülmesi

- Tekrar eden bronşit ve zatürre
- Ses kısılması
- İştahta azalma
- Herhangi bir nedeni olmadan kilo kaybı olması
- Yoğun şekilde yorgunluk hissi
- Yutkunurken zorlanılması
- Yüz ve boyun damarlarında şişkinlik

Bu belirtilerin arasına daha farklı belirtiler eklenebilmekle birlikte, akciğer kanseri hastalığının genel belirtileri bu şekilde sıralanabilir.

1.6. Tanı Yöntemleri

Akciğer kanserinin tanı ve evre testleri genellikle birlikte yapılır. İlk aşamada genel sağlık durumunun kontrolü için hastanın sigara içme geçmişi, geçirdiği veya güncel olarak kendisinde hangi hastalıklar bulunduğu, hastalıkları boyunca aldığı tedavileri de içeren bilgiler toplanır. Ardından doku, kan, idrar gibi örnekler laboratuvarlarda test edilir. Bu testler akciğer kanserinin teşhis edilmesi, tedavinin planlanması, kontrol edilmesi ve hastalığın izlenmesine yardımcı olmaktadır. Laboratuvar testlerinin yanında günümüzde sıklıkla kullanılan tanı yöntemlerinin başında görüntü yöntemleri gelmektedir. Bu yöntemler aşağıdaki şekilde sıralanabilir (Alar &Şahin, 2012).

Göğüs röntgeni yöntemi çoğunlukla akciğer kanseri teşhisi için kullanılan ilk testtir. Akciğer kanseri tümörleri röntgen ile yapılan görüntülemede gri-beyaz bir nodül olarak görülür. Ancak bu görüntüleme yönteminde akciğer apsesi ve kanser tümörleri tam olarak ayırt edilemediğinden dolayı kesin teşhis için yeterli bir yöntem değildir (Mcloud, 2002).

Bilgisayarlı tomografi (BT) taraması yöntemi genellikle göğüs röntgeninden sonra kullanılır. BT taraması yönteminde röntgen ışınları ve bilgisayar teknolojisi eş zamanlı kullanılır ve vücudun iç kısmının detaylı bir görüntüsü elde edilir. İlaçlı BT taraması yönteminde tarama yapılmadan önce vücuda belirli bir madde enjekte edilir. Bu şekilde tarama sonucunda hem daha net görüntüler elde edilir hem de tümörlerin damar komşulukları daha doğru belirlenebilir (Mcloud, 2002).

Balgam sitolojisi yöntemiyle akciğerlerden toplanan mukus, kanser hücrelerinin varlığını kontrol etmek için laboratuvar ortamında mikroskop altında incelenir.

Torasentez yöntemiyle göğsün iç kısmı ve akciğerler arasındaki boşluktan alınan sıvı kanser hücrelerinin varlığını kontrol etmek için laboratuvar ortamında mikroskop altında incelenir.

Biyopsi yöntemi, gerçekleştirilen muayene işlemleri, görüntüleme yöntemleri ve vücuttan alınan ilgili sıvıların incelenmesi sonucunda akciğer kanseri şüphesi oluşmuşsa gerçekleştirilir. Biyopsi işleminin farklı çeşitleri bulunmaktadır. Bu yöntemler aşağıdaki gibi sıralanabilir.

İnce iğne aspirasyonu yönteminde **a**kciğerde bulunan anormal doku veya sıvı görüntüleme yöntemleri ile belirlenir. İnce bir iğne kullanılarak ilgili doku veya sıvının bir miktarı çıkarılır. Sonrasında alınan örnek mikroskop altında incelenir.

Bronkoskopi yönteminde trakea ve soluk borusunda bulunan anormallikler incelenir. Lens ve ışığı bulunan bir alet (bronskop) kullanılarak burun veya ağızdan trakea ve akciğerlere sokulur ve incelenmek için örnekler alınır.

Torakoskopi yönteminde Göğüs kafesi içerisini kontrol etmek için iki kaburga arasına küçük bir kesi açılır. Açılan bu kesi bölgesine, ismi torakoskop olan görüntüleme lensi ve ışığı bulunan bir alet yerleştirilir ve incelenmesi için örnek alınır.

Mediastinoskopi yönteminde Akciğerler arasındaki dokulara ve lenf bezlerini incelemek için kullanılan cerrahi bir yöntemdir. Göğüs kemiğinin en üzerine açılan küçük bir kesiye yerleştirilen mediastinoskop aletiyle ilgili bölgeden incelenmek üzere doku ve lenf örnekleri alınır.

Moleküler test yönteminde kan, doku veya farklı vücut sıvısı örneklerinde bulunan belirli gen, protein ve molekülleri kontrol etmek için testler yapılır. Akciğer kanserinde oluşan gen ve kromozom değişiklikleri moleküler testler ile incelenir.

İmmünohistokimya yönteminde Doku örneklerinde bulunan belirli antijenleri kontrol etmek için antikorların kullanılır. Kullanılan antikor uygun radyoaktif maddeye bağlanarak mikroskop altında ayrışması sağlanmaktadır.

1.7. Evreleme

Kanser hücreleri oluştukları yerden lenf sistemi veya kan yoluyla vücut içerisinde yayılır. Kanser hücrelerinin akciğer içinde mi yayıldıkları ya da metastaz durumunda mı olduğunun belirlenmesi sürecine evreleme denir. Hastanın tedavisinin planlanması için

hastalığın evresinin belirlenmesi önemlidir. Küçük hücreli dışı akciğer kanserinin evreleri aşağıdaki gibidir (Woodard vd., 2016).

Evre I: Bu evrede kanser sadece akciğer içerisindedir ve henüz lenf bezlerine yayılmamıştır.

Evre II: Bu evrede kanserli hücreler en yakın lenf bezlerine veya henüz sadece göğüs duvarına yayılmıştır.

Evre III: Bu evrede kanser hücreleri kalp ve her iki akciğer arasındaki boşluklara yayılmıştır. Bu boşlukların yanı sıra bu bölgeye yakın yerde bulunan lenf bezlerine de yayılmıştır.

Evre IV: Bu evrede kanser beyin, karaciğer, adrenal bez, kemik ve böbrek gibi akciğerin yanında olmayan bölgelerle, lenf düğümlerine yayılmıştır.

1.8. Tedavi

Akciğer kanserinin tedavisi, hastalığın karmaşık bir yapıya sahip olmasından dolayı farklı tedavi yöntemleri gerektirmektedir. Tedaviler kanseri çeşidi ve evreleri ile doğrudan ilişkilidir. Akciğer kanserinin tedavisinde kullanılan tedavi yöntemleri aşağıdaki gibi sıralanabilir (Yılmaz, 2018).

Ameliyat ile tadavide kanserli doku ameliyat ile vücuttan tamamen atılarak ilgili bölge temizlenir. Bir hastanın akciğer kanseri olduğu belirlendiğinde ilk olarak ameliyata uygun olup olmadığı değerlendirilmektedir. Ameliyat ile tedavide kanserin yayılım durumuna göre farklı ameliyat yöntemleri uygulanır. Bu yöntemlerden ilki wedge (kama) rezeksiyon yöntemidir. Bu yöntemde tümör ve çevresindeki normal dokuların bir kısmı alınarak hastalıklı bölge temizlenir. Diğer bir ameliyat çeşidi ise lobektomi yöntemidir ve bu yöntemde tümörün yayılmasına bağlı olarak akciğerin bir lobunun çıkarılmasıyla hastalıklı bölge temizlenir. Üçüncü ameliyat yöntemi ise Pnömonektomidir. Bu yöntemde ise akciğerlerden birinin tamamen vücuttan çıkarılması gerekmektedir.

Radyasyon tedavisi **(**Radyoterapi) tedavisinde kanser hücrelerinin büyüyüp yayılmasını engellemek için yüksek enerjili ışınlar kullanılmaktadır. Radyasyon tedavisinin uygulanma şekli tedavi edilen kanser hastalığının tipine, evresine ve bulunduğu bölgeye bağlıdır. Radyasyon tedavisi kendi içerisinde harici ve dahili radyasyon tedavisi olmak üzere ikiye ayrılmaktadır. Harici radyasyon tedavisinde kullanılan bir cihaz ile kanserin bulunduğu bölgeye doğrudan ışın gönderilir. Harici radyasyon tedavisi olan stereotaktik radyoterapide

hasta, tüm tedavi seanslarında aynı pozisyonda konumlandırılır ve böylece kanserli hücrelerin bulunmadığı bölgelere zarar verilmemeye çalışılır. Dahili radyasyon tedavisinde ise kanserin bulunduğu bölgeye yerleştirilen küçük kateterler veya aplikatörler yardımıyla tedavide kullanılan radyoaktif madde ilgili bölgeye aktarılır.

Kemoterapi ile tadavi yönteminde kanser hücrelerinin büyümesi ve yayılmasını engellemek için çeşitli ilaçlar kullanılır. Bu tedavi yönteminde kullanılan ilaç ağız yoluyla alınmasının yanı sıra damar veya kas içerisine de enjekte edilebilir. Vücuda alınan ilaçlar kan dolaşımına katılır ve böylece kanserli hücrelere ulaşarak bu hücreleri hedef alınması amaçlanır. Kemoterapi tedavisinin uygulanma şekli kanserin çeşidine ve evresine göre değişiklikler göstermektedir.

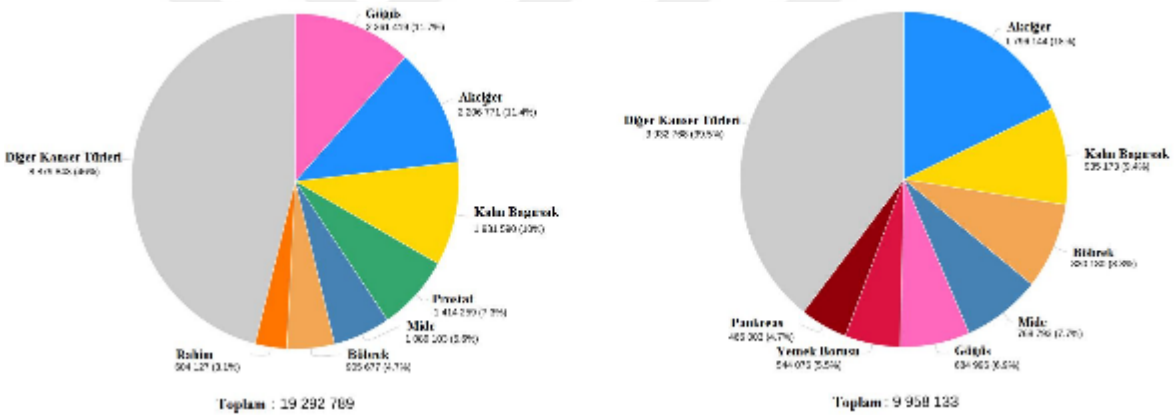
Hedefe yönelik tedavi yönteminde kanser hücrelerine etki etmesi için belirli ilaçlar ve kimyasallar kullanılır. Bu yöntemde normal hücrelere olan olumsuz etki kemoterapi ve radyoterapi tedavilerine göre daha sınırlı olmaktadır. Bu tedavi yöntemi de kendi içerisinde iki türü vardır. Bunlardan ilki monoklonal antikor tedavisidir. Bu tedavi yönteminde tek bir bağışıklık sistemi hücresi kullanılarak elde edilen antikorlar kullanılır. Kullanılan antikorlar öncelikle kanser hücrelerinin ve normal hücrelerin kimyasal yapısını tanır, ardından kanser hücrelerini hedef alarak büyüyüp yayılmalarını engeller. Bu yöntemde kullanılan antikorlar infüzyon yöntemiyle vücuda aktarılır. Hedefe yönelik tedavinin ikinci türü tirozin kinaz inhibitörleridir. Bu inhibitörler hücre zarından geçiş yapan ve kanser hücrelerinin bölünüp büyümesi için gerekli olan sinyalleri engellemek için kullanılan ilaçlardır. Bu ilaçlar kanser hücrelerinin iç yapısında çalışarak tedaviye yardımcı olmaya çalışır.

İmmünoterapi yönteminde hastanın bağışıklık sisteminin kullanılarak kanserin durdurulması amaçlanmaktadır. Vücut tarafından ya da laboratuvar ortamında üretilen maddeler vücudun kanser hastalığına karşı savaşarak doğal savunmasını artırmak ve eski haline getirmek için kullanılır. Bu tip kanser tedavisi biyoterapi veya biyolojik tedavi olarak da adlandırılmaktadır.

1.9. Çalışmanın Motivasyonu

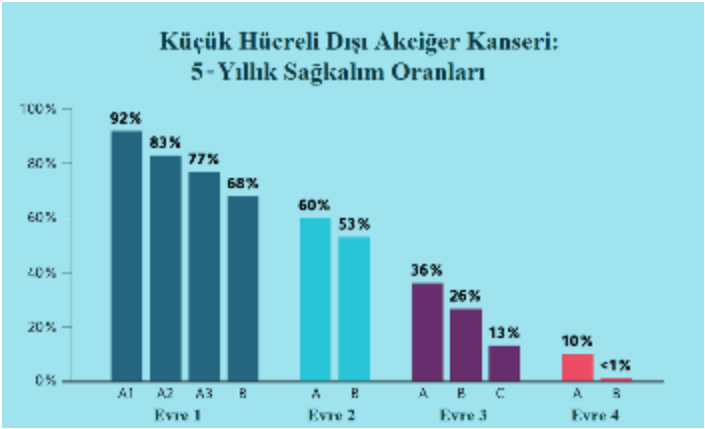
Akciğer kanseri hastalığı tüm dünyada kadınlar ve erkekler arasında en fazla ölüme sebep olan kanser türüdür. Dünya Sağlık Örgütü (WHO)' nün verilerine göre tüm dünya çapında akciğer kanseri nedeniyle hayatını kaybeden birey sayısı böbrek, bağırsak ve prostat kanseri nedeniyle hayatını kaybedenlerin sayısından daha fazladır (Siegel vd,2020),(Luque

vd. 2012). Teşhis konulan kanser hastalıkları sayısı arasında bağırsak kanserinden sonra ikinci sırada olmasına rağmen, akciğer kanseri en fazla ölüm oranının olduğu kanser türüdür. Şekil 5' te verilen dilim grafiklerde Dünya sağlık örgütünün kanser hastalıklarıyla ilgili sayısal verileri görülmektedir. Akciğer kanseri hastalığına yakalanan bireylerin sağlıklarına tekrar kavuşabilmeleri için hastalığın olabildiğince erken seviyelerde tespit edilerek tedaviye başlanması gerekmektedir. Yapılan araştırmalar göstermektedir ki, akciğer kanseri hastalığı erken evrelerde tespit edilen bireylerin 5-yıllık sağkalım oranı 80% değerine kadar ulaşabilmekteyken, hastalığı ileri evrelerde tespit edilen bireylerde bu oran 10%' a kadar düşmektedir (Aberle vd. 2011). Bu veri akciğer kanserinin erken evrelerde tespit edilmesinin ne kadar önemli olduğunu ortaya koymaktadır. Akciğer kanserinin tespit edildiği evreye göre 5-yıllık sağkalım oranlarına ilişkin değişimler Şekil 5'te verilmektedir (Blandin vd 2017).



(a) (b)

Şekil 4. 2020 yılı için tahmini olarak teşhis koyulacak (a) kanser vakalarının dağılım, (b) kanser nedenli ölümlerin dağılımı



Şekil 5. Küçük hücreli dışı akciğer kanseri 5-yıllık sağkalım oranları

Akciğer kanseri erken evrelerde belirtisi az olan bir kanser türü olduğundan dolayı, tıbbi görüntüleme yöntemleri cerrahi olarak müdahale edilebilecek tümörlerin bulunmasında en çok kullanılan yöntemlerdir (Marcus vd., 2006). Akciğer kanserinin erken tespiti için yüksek risk grubuna dahil bireyler birçok tıbbi yöntemle birlikte incelemeye alınmaktadır. Bu yöntemler genel olarak tükürük sitolojsi, vücutta dolaşımda bulunan biyobelirteç tümörler, kanın protein yapısının incelenmesi, göğüs tomografisi, nükleer manyetik rezonans, göğüs radyografisi ve düşük doz bilgisayarlı tomografi gibi manyetik rezonans kombinasyonlarıdır. Yıllardır kullanılan bu yöntemlerin teşhis koyma anlamında sınırlı özellikleri olduğundan dolayı performanslarının artırılması için çalışmalar devam etmektedir. Tıbbi görüntüleme yöntemlerinden biri olan göğüs radyografisi (GR, CXR) yöntemi geçtiğimiz birkaç on yılda, akciğer kanseri hastalarının ölüm oranında önemli bir iyileşme sağlayamamıştır (Oken vd., 2011) (Li vd., 2014). Bu yöntemin hassasiyeti düşük olmakla birlikte yüksek oranda yanlış negatif değerler de üretmektedir. Ayrıca GR yöntemindeki radyasyon şiddetinin yüksek olması bu alanda kullanılmasını sınırlamaktadır. Mazzane ve çalışma arkadaşlarının gerçekleştirdiği bir çalışmada bilgisayar destekli tomografi (BT) yönteminin geleneksel GR yönteminin bazı eksiklerini kapatabildiğini ancak yine de iyileştirilmesi gereken yanlarının olduğunu belirtmişlerdir (Mazzone vd., 2013). BT yöntemi fazla miktarda yanlış negatif değerler üretir ve çoğu ilk seviye akciğer kanseri hastalığı durumunu gözden kaçırır. Ayrıca BT yöntemi 1 mm çapından küçük lezyonları da tespit ettiğinden dolayı önemli miktarda yanlış pozitif sonuçlar da üretir, bu durum da gereksiz biyopsilere yol açmaktadır (Jantus-Lewintre vd., 2012). Bu olumsuz durumun önüne geçmek için ise pozitron emisyon taraması (PET) kullanılarak doğrulama işlemi gerçekleştirilmektedir (Karki vd. ,2013). Ancak CT ve PET yöntemlerinin maliyetlerinin yüksek oluşu akciğer kanserinin erken teşhisi uygulamasında kullanımlarını sınırlandırmaktadır.

1.10. Önerilen Yaklaşım

Kullanılan görüntüleme yöntemlerinin akciğer kanserini ilk evrelerde tespit ederek ölüm oranını azaltmada çok fazla başarı sağlayamaması araştırmacıları nefes analizi alanında çalışmalara yönlendirmiştir. Bu çalışmalarda nefes içerisindeki hastalık belirteci olabilecek uçucu organik bileşikleri (UOB) belirlemek ve tespit etmek üzerine çalışmalar yapılmaktadır. İnsan vücudunda bulunan organların çalışması sonucu oluşan kimyasal

bileşikler organlardan kana aktarılmaktadır. Kan, akciğerlerde temizlenmekte ve kanda bulunan kimyasal bileşiklerin bir kısmı nefes yoluyla vücut dışına aktarılmaktadır. İnsan nefesinde bulunan kimyasal bileşiklerin bir kısmı bireylerin bulunduğu ortamdan kaynaklı iken bir kısmı da insan vücudunun genel çalışması sonucunda ortaya çıkan bileşiklerdir. Pauling ve çalışma arkadaşları 1970 yılında yaptıkları çalışmayla insan nefesinin içeriğini araştırmışlar ve gaz kromatografisi kullanarak insan nefesinde 200 adetten fazla kimyasal bileşik belirlemişlerdir (Pauling vd., 1971). Pauling ve arkadaşlarının gerçekleştirdiği bu öncü çalışma sonrası bilim insanları nefes analizi alanında araştırmalara devam etmişlerdir. Son birkaç on yılda özellikle gelişen tıbbi elektronik cihazlar yardımıyla insan nefesinin içeriği genel anlamda tespit edilmiştir. Yapılan deneyler sonucu insan nefesinin içeriğinde temel olarak 3 tip kimyasal bulunduğu belirlenmiştir. Bu kimyasallar: Azot monoksit (NO), karbon dioksit (CO2) ve karbon monoksit (CO) gibi inorganik bileşikler, izopren, etan, pentan ve aseton gibi uçucu organik bileşikler (UOB) ve son olarak sitokinler, isoprostanlar ve azot gibi uçucu olmayan bileşiklerdir (Miekisch vd. 2004).

İnsan nefesine kan yoluyla aktarılan UOB' ler özellikle insan vücudunun biyokimyasal işleyişi hakkında önemli bilgiler vermektedir. Vücuttaki organların çalışmasında herhangi bir düzensizlik olması nefeste tespit edilen UOB miktarının da değişmesine neden olmaktadır. Günümüze değin araştırmacıların yaptıkları çalışmalar sonucu insan nefesinde gaz fazındaki UOB'lerin sayısının 3000 civarında olduğu belirlenmiştir (Behera vd.,2019). Bu uçucu organik bileşiklerin insan vücudunda üretilen çeşitleri; doymuş ve doymamış hidrokarbonlar, oksijen içeren bileşikler, sülfür içeren bileşikler ve nitrojen içeren bileşiklerdir. Doymuş hidrokarbonlar (etan, pentan) hücre zarında bulunan w3 ve w6 yağ asitlerinin reaktif oksijen türlerine maruz kalması sonucu oluşmaktadır. Doymamış hidrokarbon olan izoprenin önemli kısmı vücutta gerçekleşen kolestrol sentezi sonucunda oluşurken, küçük bir miktarı da vücuttaki bakterilerden kaynaklıdır. Oksijen içeren bileşiklerden (aseton, asetaldehit, metanol, etanol) aseton, asetoasetat'ın dekarbonizasyonu sonucunda oluşmaktadır. Asetaldehit ise vücutta üretilen etanolün oksidasyonu sonucunda oluşmaktadır. Nefes yoluyla vücut dışına atılan etanol' ün kaynağı ise bağırsaklarda yaşayan bakterilerdir. Sülfür içeren bileşikler (Dimetil Sülfid, metil ve etil merkaptanlar) genellikle vücudun boşaltım sisteminde meydana gelen düzensizlikler sonucu oluşmaktadır. Bu nedenle özellikle böbrek hastalığı bulunan bireylerin nefeslerinde sülfür içeren bileşiklerin miktarı artmaktadır. İnsan nefesindeki nitrojen içeren bileşikler amonyak ve di/trimetil amin' dir ve özellikle böbrek hastalığı olan bireylerin nefeslerinde bu uçucu organik

bileşiklere rastlanmaktadır (Davies vd., 1997). Nefes analizi konusunda literatürde bulunan çalışmalarda, vücutta meydana gelen ateşli hastalık durumunda ve sepsis hastalığı durumunda, nefesteki pentan yoğunluğu sağlıklı bireylere göre artış gösterdiği belirlenmiştir (Kokoszka vd., 1993)(Scholpp vd., 2002). Tüm dünyada oldukça sık görülen hastalıklardan biri olan şeker hastalığı bulunan bireylerin nefeslerinde de metil nitrat ve aseton bileşiklerine fazla miktarda rastlanmaktadır (Saraoğlu vd., 2013)(Huang vd., 2004). Farklı kanser türlerinin incelendiği önemli bir çalışma Peng çalışma arkadaşları tarafından gerçekleştirilmiştir. Bu çalışmada araştırmacılar akciğer kanseri, bağırsak kanseri, göğüs kanseri ve prostat kanseri olmak üzere dört farklı kanser türü üzerinde gaz kromatografisi-kütle spektrometresi (GK-KS) yöntemiyle kanser hastalarının nefeslerinde bulunan UOB'leri incelenmişlerdir. Çalışma sonucunda hasta ve sağlıklıların nefeslerinde 80% oranda birbirleriyle örtüşmeyen UOB'leri belirlemişlerdir. Belirlenen UOB' lerin sayısı akciğer kanseri için 33, bağırsak kanseri için 34, göğüs kanseri için 54 ve prostat kanseri için 36 şeklindedir (Peng vd., 2010). Çalışmalarında belirlenen UOB' lerden hasta ve sağlıklı bireylerin nefeslerinde en fazla farklılığın olduğu UOB'lerin listesi Tablo 1' de verilmektedir.

Tablo 1. Farklı kanser türleri için hasta ve sağlıklı gönüllülerin nefeslerinde en fazla farklılığın olduğu UOB'ler

	Kanser Çeşitleri			
	Akciğer Kanseri	**Göğüs kanseri**	**Bağırsak Kanseri**	**Prostat Kanseri**
Uçucu Organik Bileşikler	UOB-1	UOB-4	UOB-6	UOB-6
	UOB-2	UOB-11	UOB-7	UOB-7
	UOB-3	UOB-12	UOB-8	UOB-8
	UOB-4	UOB-13	UOB-9	UOB-9
	UOB-5	UOB-14	UOB-10	UOB-10
	UOB-6		UOB-11	UOB-11

Tablo 1' de UOB-* kısaltması ile verilen bileşiklerin tam hali şu şekildedir;

UOB-1=1-metil-4-(1-metiletil)benzen (m/z=119; CAS: 99-87-6),

UOB-2=toluen (m/z=91; CAS: 108-88-3),

UOB-3=dodekan (m/z=57; CAS: 112-40-3),
UOB-4=3,3-dimetil pentan (m/z=43; CAS: 562-49-2),
UOB-5=2,3,4-trimetil heksan (m/z=43, CAS: 921-47-1),
UOB-6=1,1'-(1-buteniliden)bis benzen (m/z=208, CAS: 1726-14-3),
UOB-7=1,3-dimetil benzen (m/z=91, CAS: 108-38-3),
UOB-8=1-iyodononan (m/z=43; CAS: 4282-42-2),
UOB-9=[(1,1-dimetiletil)tio] asetik asit (m/z=57;CAS:24310-22-3),
UOB-10=4-(4-propilsikloheksil)-4'-siyano[1,1'-bifenil]-4-il ester benzoik asit (m/z=257; CAS: 82406-83-5),
UOB-11=2-amino-5-izopropil-8-metil-1-azulenkarbonitril (m/z=224; CAS: 93946-48-6),
UOB-12=5-(2-metilpropil)nonan (m/z=57; CAS: 62185-53-9);
UOB-13=2,3,4-trimetil dekan (m/z=43; CAS: 62238-15-7),
UOB-14=6-etil-3-oktil ester 2-trifluorometil benzoik asit (m/z=173; NIST: 282650),
UOB-15=p-ksilen (m/z=91; CAS: 106-42-3), ve
UOB-16=2,2-dimetil dekan (m/z=57; CAS: 17302-37-3).
UOB' ler ile ilgili verilen detayda (m/z) ana hedef kütleyi göstermekteyken. CAS ise her bir bileşiğe ait karakteristik katalog numarasını vermektedir.

Poli ve çalışma arkadaşlarının yaptıkları bir çalışmada akciğer kanseri hastalarının nefeslerindeki aldehit sevilerini incelemişlerdir. Kanser hastalarının sigara içme durumlarının da nefese etkisinin incelendiği çalışmada elde edilen aldehit seviyeleri Tablo 2' de verilmektedir. Tablo 2' de her bir hücrenin ilk satırında verilen sayısal değerler ortalama ve standart sapma değerini (ortalama[standart sapma]) ikinci satırda yer alan değerler ise medyan değeri ile %25 ve %75' lik dilim değerlerini (medyan (%25-%75) göstermektedir (Poli vd., 2010).

Jia ve çalışma arkadaşları akciğer kanseri hastaların nefeslerinin içeriği ile ilgili yaptıkları derleme makalesinde literatürde bulunan 25 adet çalışmayı incelemişlerdir Yaptıkları incelemeler sonucunda dört veya daha fazla çalışmada akciğer kanseri hastaların nefeslerinde sağlıklı bireylere göre önemli ölçüde farklı seviyede bulunan UOB'leri Propanol, İzopren, Aseton, Pentan, Heksanal, Toluen, Benzen, Etil Benzen, Heptan, 2-Butanol, Stiren, Propanal, Pentanal, Etanol, Bütanol olarak belirlemişlerdir (Jia vd., 2019). Literatürde bulunan bu çalışmalarda nefesin içeriğini belirlemek için çoğunlukla GK-KS yöntemi kullanılmaktadır. Bu yöntemlerin yanında iyon akış tüpü kütle spektrometri

yöntemi, lazer emilim spektrometri yöntemi ve kızıl ötesi spektroskopi yöntemleri de nefes içerisindeki UOB'leri belirlemede yaygın şekilde kullanılan yöntemlerdir. Ancak bu yöntemler için gerekli cihazlar oldukça pahalıdır ve gerçekleştirilen testler de uzun süre almaktadırlar. Ayrıca bu yöntemler, UOB tespitinin performansını artırmak için nefes örneklerinin ön yoğunlaştırılmasına ihtiyaç duymaktadırlar. Bu yöntemlerin yanında nefes analizinde kullanılan cihazlardan biri de elektronik burunlardır.

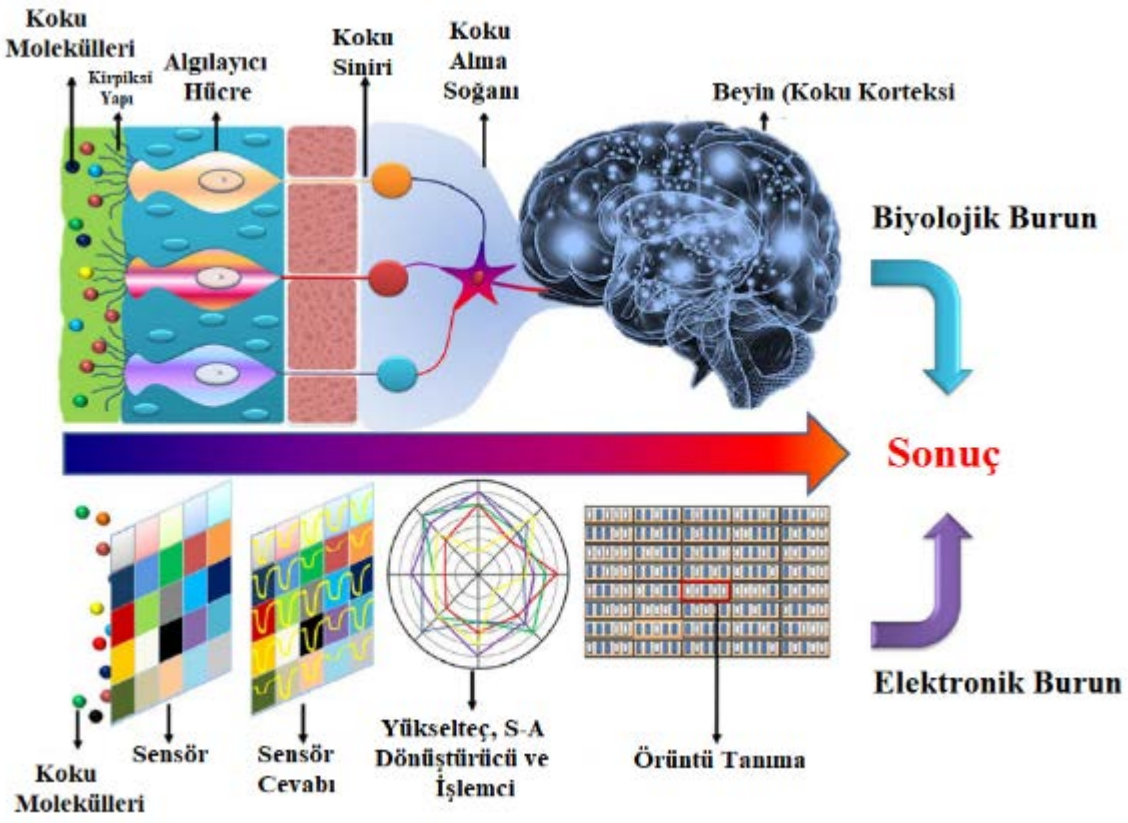
Tablo 2. Nefesteki aldehit seviyeleri

Aldehitler	**Akciğer Kanseri**	**Akciğer Kanseri**		**Sağlıklı**
		Sigara içmeyen /Sigara içmeyi bırakmış	**Sigara kullanan**	
Propanal (pM)	53.6 [1.5] 52.4 (42.4–72.6)	47.9 [1.4] 49.8 (40.7–61.3)	59.3 [1.6] 66.3 (47.8–81.7)	30.6 [2.8] 24.4 (17.1–46.9)
Bütanal (pM)	26.2 [1.8] 26.2 (18.7–41.0)	24.5 [1.7] 23.6 (17.9–33.8)	27.9 [2.0] 28.6 (19.1–46.1)	10.9 [2.4] 10.8 (6.9–18.6)
Pentanal (pM)	19.1 [2.4] 17.7 (12.7–42.6)	16.1 [2.4] 17.1 (12.8–22.3)	22.2 [2.5] 20.3 (12.1–49)	7.6 [2.7] 8.2 (4.4–14.7)
Hexanal (pM)	37.3 [1.9] 38.1 (26.6–57.7)	37.1 [1.6] 38.2 (26.7–54.6)	37.5 [2.2] 35.9 (20.9–66.7)	8.5 [2.7] 10.3 (7.0–13.8)
Heptanal (pM)	13.9 [1.8] 16.1 (9.3–21.3)	15.2 [1.6] 15.4 (10.4–21.3)	12.9 [2.1] 17.0 (8.4–24.0)	6.1 [2.0] 6.9 (3.8–10.1)
Oktanal (pM)	23.0 [1.7] 23.6 (17.7–33.2)	25.7 [1.5] 26.9 (19.1–33.5)	20.8 [1.9] 22.4 (16.9–34.2)	10.0 [1.8] 11.6 (7.2–16.2)
Nonanal (pM)	44.0 [1.8] 48.2 (31.6–62.5)	50.9 [1.7] 51.7 (32.4–72.1)	38.5 [1.9] 36.5 (31.1–60.1)	12.7 [1.8] 13.3 (7.2–22.7)

1.11. Elektronik Burun

Elektronik burun (e-burun) biyolojik koku alma sisteminden esinlenilerek üretilmiş cihazlardır. Yapılarında hem kimyasal olarak algılama sistemine hem de veri işleme sistemine sahip olması sayesinde basit veya karmaşık olan birçok kokuyu algılayabilmektedir. E-burunlar biyolojik koku alma sisteminden esinlenerek tasarlandığı

için yapı olarak biyolojik koku alma sistemiyle eşleşmektedir. E-burun koku alma sistemi ile biyolojik koku alma sisteminin karşılaştırmalı olarak gösterimi Şekil 6'da görülmektedir (Behera vd.,2019).



Şekil 6. Biyolojik burun ve e-burun ilişkisi

Şekil 6' da görülebileceği gibi biyolojik burun yapısında bulunan algılayıcı hücreler, koku soğanı ve beynin yerini e-burunlarda sırasıyla sensör dizileri, işaret işleme birimi ve örüntü tanıma birimleri almaktadır. E-burunların yapılarındaki sensör dizilerinde bulunan sensörlerin üretim teknikleri ve etkileşime girdikleri kimyasal bileşenlere göre belirli özellikleri (direnç, kapasite vb.) değişir. Sensörlerin kimyasal tepkime sonucu bu özelliklerinin değişmesi sonucu sensörlerden uygun elektriksel devreler yardımıyla elektriksel işaretler elde edilir. Ardından elde edilen bu işaretler uygun işaret işleme yöntemleriyle işlenmektedirler. Bu yöntemler arasında Şekil 6' da görülebileceği gibi sinyal yükseltme, dijital analog dönüştürme, filtreleme ve sinyal referans düzeltme gibi işlemler bulunmaktadır. Bu işlemlerin ardından elde edilen veriler örüntü tanıma biriminde işlenerek e-buruna uygulanan koku moleküllerinin hangi kokuya ait olduğuna karar verilir. Bir e-burun devresinin yapısında bulunan yapılar algılayıcı birim, dönüştürücü birim, elektronik

birim ve örüntü tanıma birimdir. E-burunları oluşturan bu birimlerin detaylı olarak açıklaması aşağıda verilmektedir.

1.11.1. Algılayıcı Birim

E-burun devrelerinin en temel parçalarından biri olan algılayıcı birimin temel elemanı kimyasal sensörlerdir. Kimyasal sensörler, kendilerine uygulanan kimyasalların özelliklerine bağlı olarak bir elektriksel işaret oluştururlar ve böylece sınıflandırma algoritmaları ile hangi sınıfa ait olduğu belirlenecek olan işaretler elde edilmiş olur. E-burunlarda kullanılan sensör çeşitleri aşağıdaki gibi verilebilir (Behera vd.,2019).

Elektrokimyasal sensörlerde algılayıcı malzeme metal oksit yarıiletken veya organik iletken polimer malzemeler kullanılmaktadır. Sensörlere uygulanan kimyasal bileşenler sensör yapısında bulunan algılayıcı malzemelerle kimyasal tepkimeye girerler ve bu tepkime sonucu sensörlerde bulunan algılayıcı malzemelerinin elektriksel iletkenlikleri değişir. Sonrasında da bu değişim uygun elektriksel devrelerle algılanıp gerektiğinde düzenlenerek bilgisayara kaydedilir. Bu çalışmada da kullanılan sensörlerden biri olan metal oksit yarıiletken (MOY) sensörler e-burun uygulamalarında sıklıkla kullanılmaktadırlar. MOY sensörler ilk olarak Taguchi tarafından 1968 yılında ticari hale getirilmiştir. Sensör algılayıcı malzemelerinin hedef gazlarla kimyasal tepkimeye girebilmeleri için yapılarında ısıtıcı bir bobin bulunmaktadır. Sensör algılayıcı malzemesi olarak çoğunlukla kalay oksit (SnO_2) ve az miktarda platin (Pt) ve paladyum (Pd) kullanılmaktadır. Bazı MOY sensörlerde kalay oksit malzemesinden farklı olarak titanyum oksit (TiO_2), tungsten oksit (WO_3)ve çinko oksit (ZnO) de algılayıcı malzeme olarak kullanılmaktadır. Kullanılan metal oksit malzemenin algılanacak malzeme ile tepkimeye girdiğinde üzerinde belirli kimyasal yükseltgenme ve indirgenme tepkimeleri oluşur, tepkime sonucu oluşan iletkenlik değişimi bu tepkimeler sonucu oluşmaktadır. Yükseltgenme durumunun oluşması için oksidasyon aşamasında ortamda bulunan oksijen sensör yapısında bulunan metal okside tutunur ve iletken banttaki elektronların yakalanmasıyla sensör direnci artar. İndirgenme durumunda ise metal oksidin yüzeyinde bulunan elektronlar algılanacak olan kimyasal bileşenlerle tepkimeye girerler ve sonuç olarak yükseltgenme aşamasında iletken banttan ayrılmış olan elektronlar tekrar iletken banda dönerler. Sensör direncindeki değişim algılayıcı metal oksidin yüzeyine tutunmuş oksijen miktarına ve kullanılan metal oksidin tane yapı ve büyüklüğüne de bağlıdır. MOY sensörlerin çalışma sıcaklıkları genellikle 300°C-500°C

aralığındadır ve bu sıcaklık hem sensörün hedef gazlara hızlı tepki vermesini hem de gerçekleşen kimyasal tepkime sonucu ortaya çıkan suyun hızlıca ortamdan kaybolmasını sağlar.

Organik iletken polimer sensörler de metal oksit yarıiletken sensörler gibi iletkenlik değişim esasına göre çalışırlar. Yapılarında genel olarak polipirol, polianilin, politiyofen ve poliasetilen malzemeleri kullanılmaktadır. Bu sensörlerin uygulamadaki en önemli sorunu kullanıldıkça sensörde bulunan polimerin oksidasyona uğraması sonucu oluşan nem ve sensör kaymalarıdır.

Gerilim ölçümüne dayalı sensörlerin yanı sıra akıma dayalı gaz sensörlerine de e-burun uygulamalarında rastlanmaktadır. Bu sensörlerin yapısında genellikle altın ve platin bulunmaktadır ve SO_2, NO ve CO_2 gibi gazların algılanması uygulamalarında sıklıkla kullanılmaktadırlar. Bu sensörlerin sabit gerilim altında, algılanacak olan gaz ile tepkimeye girdiklerinde sensör çıkış akımları değişmektedir. Örneğin ppm yoğunluğundaki gazlarla tepkimeye girmeleri sonucunda sensör çıkış akımları mikro ve piko amper sevilerinde değişikliğe uğramaktadır. Böylece algılanan bu akım değişimi hedef gazın belirlenmesi için kullanılmaktadır. Bu sensörlerin en önemli avantajı hassasiyetlerinin yüksek olması, düşük maliyetli olmaları ve kullanım ömürlerinin uzun olmasıdır.

Isıl Sensörler literatürde yanıcı gaz sensörleri veya katalitik sensörler olarak da adlandırılırlar. Isıl sensörler, uygun katalitik çubuğun ince sargılar haline getirilerek sensör yapısına eklenmesiyle oluşturulur. Yapılarında bulunan platin kablolar rezistif bir termometre olarak davranır. Sensör sıcaklığı 500°C dereceye kadar yükseltildiği durumda sensörün hidrokarbonla temas etmesi sonucu katalitik oksidasyon tepkimesi oluşur ve ortamdan bir miktar ısı transferi gerçekleşir. Transfer edilen ısı sensörün yapısında bulunan platin kabloların direncini değiştirir. Bu sensörler genellikle Wheatson köprü devresinde uygun yere yerleştirilir ve platin kabloda meydana gelen direnç değişimi yardımıyla hedef gazların değişimi algılanabilir.

Optik sensörler de kimyasal algılamada sıklıkla kullanılan sensör çeşitlerinden biridir. Bu sensörler ölçüm yaparken yoğunluk bilgisinin yanında dalga boyu bilgisini de elde etmektedir. Bu tip sensörlerin yaygın kullanılan çeşitleri emilim sensörleri, yansıtıcı sensörler ve florasan sensörlerdir. Florasan sensörleri algılama için yapılarında bulunan optik fiberlerden faydalanırlar. E-burun yapısında kullanılan fiber optik sensörlerde polimer boya ile kaplanmış fiber optik malzeme kullanılır. Polimer/boya değişimlerindeki farklılıklar algılama özelliklerinde de farklılığa sebep olmaktadır. Bu yönteme alternatif olarak farklı

boya ve polimerler kullanılmaktadır. Optik sensör diziler oluşturmak genelde iki farklı yolla yapılır. Bu yolların ilkinde birden fazla fiberin bir arada ve yüzey üzerinde foto polimerleşmiş sensör bölgelerinin kaynaşması esasına dayanmaktadır. İkinci yöntem ise fiber üzerine yerleştirilen algılama çubuklarında oluşan kimyasal aşındırma esasına dayanmaktadır.

Yansıtıcı sensörlerde reflektometrik girişim spektroskop yöntemi gaz algılamak için kullanılabilir. Bu yöntemde, sensörlerin algılaması için beyaz ışık interferometrisi kullanılır ve bu sayede polimer algılama tabakasındaki değişiklikler ölçülür. Farklı algılama tabakalarının kullanılması tercih edildiği takdirde sistem sensör dizisi haline getirilebilir.

Porfirin tabanlı sensör dizileri emilim tipi sensörlerdendir. Porfirin halkalar, geçiş metal iyonları ile yüksek kararlı şekilde biçimledirilmesiyle Soret bandı adı verilen bant aralığında emilim ile yüksek seviyede kromojen davranış gösterirler. Metal porfirin gaz molekülleri ile etkileşimi sonucu soğurma tayfında farklılıklar oluşmaktadır .

Gravimetrik sensörlerin temeli piezoelektrik kristallere dayanmaktadır. Bu kristaller elektronik devrelerde, haberleşme elektroniğinde devrelerinin yapısında bulunan filtre devrelerinde, optoelektronik cihazlarda ve sıvı-gaz algılayıcı cihazlarda kullanılmaktadır. Gazların algılanması için en fazla kullanılan piezoelektrik malzemeler kuvarslar ve $LiNbO_3$ tür. Bu malzemelerden farklı olarak bükülgen plaka dalgası (BPD), kütle ses dalgası (KSD) ve yüzey ses dalgası (YSD) sensörleri de uygulamada oldukça fazla kullanılmaktadır. KSD sensörlerinde kullanılan kuvars kristal malzemenin her iki yanına altın plakalar yerleştirilir. Sensörün temel frakansı kuvars kristal malzemenin kütlesine bağlı olarak değişir. Bu sensörlerin temel frakansı genel olarak 10 MHz ile 30 MHz arasında değişmektedir. Sensör yüzey ağırlığının 1ng değişimi sensör temel frakansında 10Hz' lik bir frekans değişimine sebep olmaktadır. Diğer bir gravimetrik sensör çeşidi olan YSD sensörler de hedef gazlara karşı hassas ince bir film tabakayla kaplanır. Sensörlerin hedef gaz ile temasında ince film üzerinde tutunan parçacıklar sensör ağırlığını artırır ve bu sayede sensörün rezonans frekansında değişiklikler meydana gelir. Algılanan bu frekans değişiklikleri kullanılarak hedef gaz hakkında bilgi edinilmeye çalışılır. Diğer bir piezoelektrik sensör olan BPD sensörleri de YSD sensölere benzer şekilde çalışır. Algılayıcı olarak kullanılan polimer malzemenin yapısına çinko oksit ve silikon püskürtülerek algılayıcı yapı hazırlanmış olur. Bu sensör çeşidi KSD ve YSD sensörlere göre daha düşük enerji tüketim seviyesine ve gürültü seviyesine sahiptir. Literatürde e-burun uygulamalarında sıklıkla kullanılan sensör çeşitleri Tablo 3' te verilmektedir (Pearce, vd., 2003).

Tablo 3. E-burun uygulamalarında kullanılan sensörler

Prensip	Ölçülen Büyüklük	Sensör Tipi	
İletkenlik ölçümüne dayalı	İletkenlik	Kimyasal direnç	MOS
			İletken polimer
Kapasitif	Kapasite	Kimyasal kapasite	Polimer
Gerilim değişimine dayalı	Gerilim	Kimyasal diyot	Şotki diyot
	I-V / V-C	Kimyasal transistör	MOSFET
Isıl ölçüme dayalı	Sıcaklık	Isıl Kimyasal sensör	Termistör, Termokupl
Ağırlık ölçümüne dayalı	Piezoelektrik	Kütle hassasiyetine dayalı kimyasal sensör	QCM, SAW
Işınsal	Işığın kırılması	Titreşimli tip kimyasal sensör	SPR
	Yoğunluk/ Tayf	Fiber optik kimyasal sensör	Floresan, kimyasal ışıldama
Akım ölçümüne dayalı	Akım	Toksik gaz sensörü	Elektrokatalist

1.11.2. Dönüştürücü Birim

E-burunlarda kullanılan dönüştürücü birimin amacı, hedef gazların sensörlerle tepkimeye girmeleri sonucu sensörlerde oluşan değişikliklerin elektriksel işaretlere dönüştürülmesini sağlamaktır. Dönüştürücü devreler olarak kullanılan devreler arasında genellikle doğru akım ve alternatif akım köprüleri gösterilebilir. Ancak bu çalışma kapsamında kullanılan gerilim bölücü devresi de sıklıkla kullanılan devrelerden biridir. Özellikle gerçekleştirilmesinin ve kullanımını basit olması gerilim bölücü devrelerini tercih edilir kılmaktadır. Sensör direnç değişiminin sınırlı olduğu devrelerde yüksek kazancından dolayı doğru akım köprüleri gerilim bölücü devreler yerine tercih edilmektedir. Frekans tabanlı bilgilerin elde edildiği akustik dalga sensörlerinde (YSD, QCM, KSD) dönüştürücü devresi olarak rezenatör filtre devreleri kullanılır. Kullanılan bu filtre devresi yardımıyla sensörlerde oluşan frekans değişimi algılanabilir.

1.11.3. Elektronik Birim

Dönüştürücü devreler yardımıyla sensör tepkileri elektriksel işaretlere dönüştürülür, elde edilen bu işaretler bilgisayara aktarılmadan önce yükselteç devreleri, tampon devreleri ve filtre devreleri gibi devrelerle iyileştirilmeleri gerekebilmektedir. Tampon devreleri farklı birimler arasında empedans uyumunun sağlanması için sıklıkla kullanılan devrelerdir. Elde

edilen elektriksel işaret D-A dönüştürücü tarafından algılanacak seviyede değilse bir yükselteç devresiyle bu işaretler uygun seviyeye getirilebilir. Sensörlerden elde edilen işaretlerde herhangi istenmeyen frekanslı bir işaret olması durumunda filtre devreleri kullanılarak istenmeyen frekanslı işaretler elimine edilebilir. Bu devreler haricinde eğer ihtiyaç duyulmaktaysa türev alıcı, integral alıcı, logaritma alıcı veya doğrusallaştırıcı devreler de kullanılmaktadır.

1.11.4. Örüntü Tanıma Birimi

Elektronik burun kullanılarak gerçekleştirilen koku tanıma sistemlerinde işaretler sensörlerden alınır ardından analog dijital dönüştürme işlemiyle birlikte bilgisayara aktarılmaya hazır hale gelir. Bu çalışma kapsamında örüntü tanıma işlemi ile ilgili yapılan işlemler Şekil 7' de gösterilmektedir.



Şekil 7. Çalışmada kullanılan işaret işleme aşamaları

Örüntü, üzerinde çalışılan konu ile ilgili gözlenebilen ve ölçülebilen verileri tanımlamak için kullanılan bir kelimedir. Örüntü tanıma işlemi ise insanların çeşitli görüntü, ses ve bu büyüklüklere benzeyen örüntülerin biçimlerinden çıkarım yaptıkları dilsel şekillendirmelerdir. İnsanlarda örüntü tanıma geçmişlerinde edindikleri tecrübelerden faydalanarak yeni durumlar hakkında karar verebilmeleri şeklindedir. Bu şekilde insanlar daha önceden tecrübe sahibi oldukları konularla ilgili yeni bir durumla karşılaştıklarında doğru kararlar verebilir. Veri işleme alanında örüntü tanımanın tanımını yapmak gerekirse; aralarında benzer özellikler ve ilişkiler bulunan işaret örneklerinin tespit edilen belirli özellikler yardımıyla tanımlama ve sınıflandırma işlemidir denebilir.

Günümüzde örüntü tanıma yöntemleri mühendislik tıp askeri ve bilim alanları gibi birçok alanda kullanılmaktadır. Bu alanlara örnek verecek olursak; ses tanıma, beyin işaretlerinin sınıflandırılması, veri madenciliği, biyolojik sinyal işleme, radarların hedeflerinin sınıflandırılması gibi uygulamalar verilebilir.

Koku algılama sistemlerinde farklı kokuların kümeler halinde ifade edilmesi ile bu kokulara ait belirli özellikler kullanılarak bir veri tabanı oluşturulmaktadır. Elde edilen veri

tabanı kullanılarak örüntü tanıma sisteminin eğitilmesi sağlanır. Bu eğitim işleminin amacı e-burun sisteminin kendisine tanıtılan kokulara ait verilerle eğitilmesi, ardından kendisine uygulanan yeni kokulara ait verilerin doğru şekilde sınıflandırılmasını sağlamaktır. Sensörlerden elde edilen işaretler örüntü tanıma biriminde ilk olarak işaret koşullama ve işaret ön işleme birimine gelir. Bu birimde eğer gerek duyuluyorsa işaretler filtrelenir, farklı teknikler kullanılarak dönüştürülür ve modelleme yapılabilir. Öznitelik çıkarma ve boyut indirgeme biriminde ise verilerin sınıflarını en iyi şekilde temsil edecek olan öznitelikler belirlenir ve bu öznitelikler kullanılarak öznitelik matrisi oluşturulur. Elde edilen öznitelik matrisi üzerinde hiçbir değişiklik yapmadan veri sınıflandırma yapılabileceği gibi öznitelik matrisinin boyutu azaltılarak da sınıflandırma yapılabilir. Bu doktora çalışmasında boyut indirgeme algoritması olarak Temel Bileşen Analizi (TBA) ve Doğrusal Ayrıştırma Analizi (DDA) yöntemleri kullanılmıştır. Elde edilen öznitelik matrisini sınıflandırma için ise Karar Ağaçları (KA), farklı çekirdek fonksiynlarının kullanıldığı Destek Vektör Makineleri, k-En Yakın Komşu (k-EYK), Rastgele Orman (RO) ve Bulanık Mantık Yöntemi (BMY) algoritmaları kullanılmıştır. BMY yönteminde kullanılan üyelik fonksiyonlarının parametrelerinin optimize edilmesi için 5 adet meta-sezgisel optimizasyon algoritması kullanılmıştır. Bu algoritmalar Genetil Algoritma GA), Parçacık Sürü Optimizasyonu (PSO), Benzetimli Tavlama (BT), İstilacı Yabani Ot Optimizasyonu (İYO) ve Yapay Ekosistem Optimizasyonu (YEO) algoritmalarıdır. Tüm bu algoritmalara ilişkin bilgiler aşağıda verilmektedir.

1.11.5. Temel Bileşen Analizi

Bu çalışmada kullanılan boyut azaltma algoritmalardan ilki Temel Bileşen Analizi (TBA) ilk olarak Karl Pearson tarafından 20 yüzyıl başlarında geliştirilmiş bir yöntemdir daha sonra Hotelling, ve Rao tarafından farklı uygulamalı alanları üzerinde kullanılarak literatürde önemli bir yer tutmuştur (Timm, 2002). TBA kullanılarak değişkenler arasında var olan bağımlılık ortadan kaldırılır ve bu değişkenlerin oluşturduğu veri tabanının boyutu azaltılabilir. Değişkenler arasında bağımlılık bulunması istatistiksel analizi veri boyutu yüksek olduğundan dolayı zorlaştırabilmektedir. Temel bileşen analizi kullanılarak gereksiz veriyi ortadan kaldırarak daha hızlı bir şekilde işlem yapılması sağlanabilir. Bu analiz ile boyutu indirgenecek olan N adet gözlem sayısı ve s adet değişkene sahip bir X veri ele alındığı varsayılsın. Bu X veri matrisi (1) ve (2) denklemlerdeki gibi verilebilir.

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1s} \\ x_{21} & x_{22} & \dots & x_{2s} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{ns} \end{bmatrix} \quad (1)$$

$$X_1 = \begin{bmatrix} x_{11} \\ x_{21} \\ \dots \\ x_{n1} \end{bmatrix}, X_2 = \begin{bmatrix} x_{12} \\ x_{22} \\ \dots \\ x_{n2} \end{bmatrix}, \dots, X_s = \begin{bmatrix} x_{1s} \\ x_{2s} \\ \dots \\ x_{ns} \end{bmatrix} \quad (2)$$

Matematiksel olarak X_1, X_2 ve X_s değişkenleri birbirleri ile ilintili ise temel bileşen analizi ile birlikte bu değişkenlerin koordinat eksenleri döndürülerek birbirinden bağımsız olması amaçlanmaktadır. TBA yönteminde ilk yapılan işlemlerden biri (*N*x*S*) boyutlu X veri matrisinin varyans kovaryans matrisinin hesaplanması işlemidir. Bu matrisin oluşturulması için (3) denklemi kullanılabilir.

$$Cov(X,Y) = \frac{\sum_{i=1}^{n}(X_i - \bar{X})(Y_i - \bar{Y})}{(n-1)} \quad (3)$$

(3) denklemi kullanılarak elde edilen S, varyans kovaryans matrisi (4) denklemindeki gibi verilebilir.

$$S = \begin{bmatrix} s_{11} & s_{12} & \dots & s_{1s} \\ s_{21} & s_{22} & \dots & s_{2s} \\ \dots & \dots & \dots & \dots \\ s_{s1} & s_{s2} & \dots & s_{ss} \end{bmatrix} \quad (4)$$

Ardından *S*, varyans kovaryans matrisinin (5) denklemi kullanılarak özdeğerleri hesaplanır.

$$|S - \lambda I| = 0 \quad (5)$$

(5) denkleminin çözümü için öz değerlerinin s. dereceden bir polinomu oluşturularak s adet kök yani s adet özdeğer hesaplanır. Elde edilen s adet özdeğer'e karşılık s adet de özvektör bulunmaktadır ve en büyük öz değere karşılık gelen öz vektör temel bileşen olarak adlandırılır.

Temel bileşen analizinde en önemli konulardan biri de kaç adet özdeğere karşılık gelen özvektörün veri boyutu azaltılması için kullanılacağıdır. Literatürde bu konuda yapılan

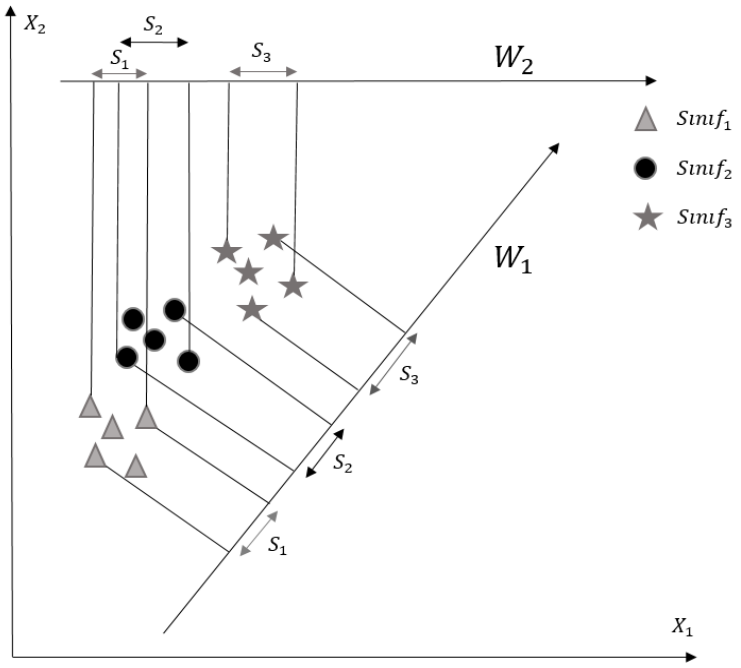
çalışmalarda seçilecek olan öz değerlerin toplamının bütün öz değerlerin toplamına oranının %90'ın üzerinde olması gerektiği şeklindedir. Bu çalışmada da temel bileşen analizi yöntemi ile veri boyutu azaltımı yapılırken seçilen özdeğerlerin toplamanın tüm özdeğerlerin toplamına oranı minimum %90 olacak şekildedir. Kullanılacak olan öz değerlerin sayısı öz değer ve öz vektörlerin sayısı belirlendikten sonra veri boyutunun azaltılması (6) denklemi kullanılarak gerçekleştirilir.

$$G_T = V_1^T x X^T \tag{6}$$

Bu denklemde V_1^T seçilen öz vektörlerin oluşturduğu matrisi X^T ise boyutu indirgenecek olan orijinal veri matrisini ve $G_T{}'$ temel güneş'in analizi ile birlikte boyutu indirgenmiş olan veriyi göstermektedir.

1.11.6. Doğrusal Ayrıştırma Analizi

Bu çalışmada kullanılan diğer bir boyut indirgeme yöntemi de Doğrusal Ayrıştırma Analizi (DDA) yöntemidir. DDA yöntemi yüksek boyutlu bir öznitelik matrisinin boyutunu, uygun bir w düzlemi üzerine izdüşümünü alarak boyut azaltımı yapan bir algoritmadır. Öznitelik matrisinin w düzlemi üzerine izdüşümü alınırken sınıf içi dağılımın mümkün olduğu kadar küçük, sınıflar arası dağılımın ise olabildiğince büyük olması istenmektedir. DDA yöntemine ilişkin görsel Şekil 8' de verilmektedir. Şekil 8' de görüldüğü gibi 2 boyutlu uzaydaki 3 sınıflı bir öznitelik matrisi w_2 düzlemi üzerine izdüşümü alınırsa $Sınıf_1$ ve $Sınıf_2$ verileri birbirine karışmaktadır. Bu durumda sınıflar arası dağılım istenen şekilde olmamaktadır. Ancak öznitelik matrisini izdüşümü w_1 düzlemi üzerine alınırsa, tüm sınıflara ait veriler birbirlerinden ayrılabilmektedir. Bu yöntemde verilerin izdüşümünün alınacağı düzlemin belirlenmesi için literatürde Fisher ayrım fonksiyonu olarak da bilinen $J(w)$ fonksiyonunun optimize edilmesi gerekmektedir.



Şekil 8. DDA yöntemine ilişkin görsel

Fisher ayrım fonksiyonu 3 parametreye bağlıdır. Bu parametreler w düzlemi, sınıf içi dağılım matrisi s_w ve sınıflar arası dağılım matrisi s_B dir. DDA tekniğinin matematiksel açıklamaları aşağıdaki şekilde verilebilir. c_1 ve c_2 sınıflarına ait verilerin sayıları sırasıyla n_1 ve n_2 olsun. x_i veri noktalarının herhangi bir w düzlemi üzerine izdüşümü $w^T x_i$ denklemiyle elde edilir. n_1 boyutlu c_1 sınıfına ait verilerin w düzlemi üzerine izdüşümü yapıldıktan sonra yeni oluşan verilerin ortalama değeri (7) denklemi kullanılarak elde edilir.

$$\widehat{\mu_1} = \frac{1}{n_1} \sum_{x_i \in c_1}^{n_1} w^T x_i = w^T \mu_1 \tag{7}$$

(7) denkleminde μ_1, c_1 sınıfına ait verilerin ortalama değerini göstermektedir. Benzer şekilde c_2 sınıfına ait verilerin izdüşümü yapıldıktan sonra oluşan verilerin ortalama değeri $\widehat{\mu_2} = w^T \mu_2$ şeklinde elde edilir. $w^T x_i$ ifadesini y_i şeklinde kısaltarak gösterirsek, c_1 sınıfının izdüşümü yapılan verilere ait dağılımı (8) denklemiyle hesaplanır.

$$\widehat{s_1^2} = \sum_{y_i \in c_1} (y_i - \mu_1)^2 \tag{8}$$

Benzer şekilde ikinci sınıfa ait veriler için oluşan dağılım ifadesi $\widehat{s_2^2} = \sum_{y_i \in c_2} (y_i - \mu_2)^2$ şeklinde elde edilir.

DDA tekniğinde sınıf içi dağılımı minimum, sınıflar arası dağılımı maksimum yapmak için (9) denklemi maksimum yapılmalıdır.

$$J(w) = \frac{\widehat{\mu_1} - \widehat{\mu_2}}{\widehat{s_1^2} - \widehat{s_2^2}} \tag{9}$$

$\widehat{\mu_1}$, $\widehat{\mu_2}, \widehat{s_1^2}$, ve $\widehat{s_2^2}$ değerleri w cinsinden yerine yazılırsa $J(w)$ ifadesi (10) denklemindeki gibi yeniden elde edilir.

$$J(w) = \frac{w^T S_b w}{w^T S_w w} \tag{10}$$

(4) denkleminde S_b, sınıf içi dağılım ifadesini temsil etmekteyken, S_w ise sınıflar arası dağılımı ifade etmektedir. Orijinal öznitelik matrisinde c_1 ve c_2 sınıflarına ait varyans ifadeleri (11) ve (12) denklemlerindeki gibi hesaplanır

$$s_1 = \sum_{x_i \in c_1} (x_i - \mu_1)(x_i - \mu_1)^T \tag{11}$$

$$s_2 = \sum_{x_i \in c_2} (x_i - \mu_2)(x_i - \mu_2)^T \tag{12}$$

(11) ve (12) denklemlerinin kullanılmasıyla sınıf içi dağılım matrisi S_w ve sınıflar arası dağılım matrisi S_b (13) ve (14) denklemlerindeki gibi elde edilir.

$$S_w = s_1 + s_2 \tag{13}$$

$$S_b = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T \tag{14}$$

(13) ve (14) denklemlerindeki ifadelerin (10) denkleminde yerine konmasıyla elde edilen $J(w)$ ifadesinin w' ya göre birinci dereceden türevi alınır ve sıfıra eşitlenirse (15) denklemi elde edilir.

$$\frac{dJ(w)}{dW} = S_b w - \frac{w^T S_b w (S_w w)}{w^T S_w w} = 0 \tag{15}$$

$\lambda=\frac{w^T S_b w}{w^T S_{bw} w}$ ve $M = S_w^{-1} S_b$ dersek eşitlikleri kullanılarak(16) denklemi elde edilir.

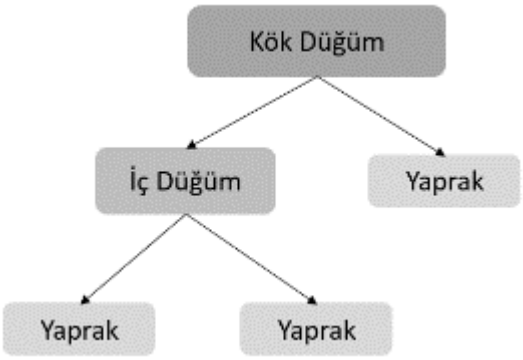
$$Mw = \lambda w \tag{16}$$

(16) denklemi temel bir özdeğer özvektör problemine karşılık gelmektedir ve M matrisine ait özdeğerlerin en büyük değerli olanları $J(w)$ ifadesini maksimum yapmaktadır.

Öznitelik çıkarma ve boyut azaltma işleminden sonra verilerin hangi sınıflara ait olduklarının belirlenmesi için veri sınıflandırma işlemi gerçekleştirilir.

1.11.7. Karar Ağaçları

Bu çalışmada ilk olarak kullanılan sınıflandırma algoritması Karar Ağaçları (KA) algoritmasıdır. Karar ağacı algoritması veri sınıflandırma ve tahmin uygulamalarında sıklıkla kullanılan bir yöntemdir. Bu yöntemde eğitim verisi kullanılarak bir ağaç modeli geliştirilir. Ardından test verilerinin kullanılmasıyla oluşturulan ağacın performansının incelenir ve son olarak sınıflandırılacak olan veriler oluşturulan ağaca aktarılarak ait oldukları sınıflara atanırlar. Karar ağaçları herhangi bir girdisi olmayan kök düğümü ve her birinin girdileri olan iç düğümlerden oluşmaktadır. Çıktıları farklı bir düğüm ile birleşen düğümlere iç düğüm, herhangi bir çıktısı olmayan düğümlere ise yapraklar denmektedir. Karar ağaçlarındaki yapraklar her bir sınıfa ait sınıfları temsil etmektedir. Bu yöntemde iç düğümler öznitelik matrisinde bulunan özniteliklerin değerlerine göre farklı şekillerde parçalara ayrılmaktadır. Genel bir karar ağacının yapısı Şekil 9’ da verilmektedir. Karar ağaçlarında eğitim verisinin kullanılarak hangi özniteliğin kök düğüm hangilerinin iç düğümler olacağına, bu düğümlerden her birinin hangi sırada bulunacağına karar vermek için kullanılan bazı algoritmalar vardır. Bu algoritmalar genelleştirme hatasının en düşük değerde olmasını hedeflemelerinin yanında ağacın boyu ve düğüm sayısı gibi özelliklerin de optimum hale getirilmesini sağlarlar. Yapılacak çalışmalarda ağacın küçük boyutlu ve derinliğinin az olması amaçlanır. Büyük boyutlu ve derinliği fazla olan ağaçlarda genelleştirme başarına düşük değerlerde olmaktadır. optimum hale getirilmesini sağlarlar. Yapılacak çalışmalarda ağacın küçük boyutlu ve derinliğinin az olması amaçlanır. Büyük boyutlu ve derinliği fazla olan ağaçlarda genelleştirme başarına düşük değerlerde olmaktadır.



Şekil 9. Karar Ağaçları Genel Yapısı

X C4.5 algoritması literatürde en fazla kullanılan karar ağacı algoritmalarından biridir. Bu algoritmada öncelikle veri setindeki her bir sınıfa ait entropi değeri (17) denklemi kullanılarak hesaplanır.

$$Entropi(S) = \sum_{i=1}^{c} -p_i \log_2 p_i \tag{17}$$

(17) denkleminde c, sınıf sayısını temsil ederken, p_i ise her bir sınıfın tüm sınıflar arasındaki olasılığını temsil etmektedir. (17) denklemindeki işlemin ardından her bir özniteliğe ait bilgi kazancı hesaplanır. Veri setindeki özniteliklere ait kazanç değerinin hesaplanması (18) denklemiyle gerçekleştirilir.

$$Kazanç(S, A) = Entropi(S) - \sum_{i=1}^{n} \frac{S_i}{S} xEntropi(S_i) \tag{18}$$

(18) denkleminde $Gain(S, A)$ ifadesi, A özniteliğinin tüm veri setinin üzerinde ne kadar etkisi olduğunu göstermektedir. S_i ise S özniteliğine karşılık gelen S_i özniteliklerinin olasılıklarının sayısıdır. (17) ve (18) denklemlerinden elde edilen bilgilerle SplitInfo değeri (19) denklemi kullanılarak elde edilir. $SplitInfo(S, A)$ ifadesi herhangi bir A özniteliğinin eğitim verisi içerisindeki entropi değerini ifade etmektedir.

$$SplitInfo(S,A) = -\sum_{i=1}^{n} \frac{S_i}{S} \log_2 \frac{S_i}{S} \tag{19}$$

Son olarak her bir öznitelik için kazanç oranı (20) denklemiyle hesaplanır.

$$GainRatio(A) = \frac{Gain(S,A)}{SplitInfo(S,A)} \tag{20}$$

C4.5 algoritmasını kullanan karar ağaçlarında kök düğümü öznitelik seçimi en yüksek kazanç oranı değerine sahip olan özniteliğin seçilmesiyle başlar.

Literatürde kullanılan bir diğer karar ağacı algoritması bu tez çalışması kapsamında kullanılan karar ağacı algoritması CART algoritmasıdır. Bu algoritmanın çalışma prensibi gini indeks olarak adlandırılan bir işlem üzerine kuruludur. Bu yöntemde n sınıf içeren ve T olarak adlandırılan bir veri setinde her bir sınıfa ait gini indeks değeri (21) denklemiyle hesaplanır.

$$gini(T) = 1 - \sum_{j=1}^{n} p_j^2 \tag{21}$$

(21) denkleminde p_j, j. sınıfın tüm sınıflar arasındaki olasılığını göstermektedir. T veri setinin boyutları sırasıyla N_1 ve N_2 olacak şekilde T_1 ve T_2 parçalarına bölünmüş olduğu varsayılsın. Bölünmüş olan veri setine ait gini indeks değeri (22) denklemi kullanılarak hesaplanır.

$$gini_{böl}(T) = \frac{N_1}{N} gini(T_1) + \frac{N_2}{N} gini(T_2) \tag{22}$$

Her bir öznitelik için yapılan bu işlemler sonucunda en düşük gini indeks değerini sağlayan öznitelik kök düğümü olarak belirlenir.

Literatürde sıklıkla kullanılan diğer bir karar ağacı yöntemi ki-kare testi kullanılarak ağacın dallanmasını sağlayan CHAID algoritmasıdır. Bu yöntemde her bir düğümde ki-kare testi uygulanarak ağacın yapısı için en uygun öznitelik (23) denklemi kullanılarak belirlenir.

$$X^2 = \sum_J \frac{(x_{ij} - E_{ij})^2}{E_{ij}}, \qquad i = 1, \dots, n \tag{23}$$

(23) denkleminde x_{ij} ve E_{ij} değerleri, j. sınıfa ait öznitelik değerlerini ve beklenen değeri göstermekteyken n ise öznitelik sayısını göstermektedir. CHAID algoritmasında en büyük X^2 değerine sahip öznitelik kök düğüm olarak belirlenir.

Karar ağaçlarında aşırı öğrenme durumlarında budama işlemi de yapılmaktadır. Oluşturulan karar ağaçlarında verilerin doğru sınıflandırılmasına katkısı olmayan dallar budanabilmektedir. Budama işleminde iki yöntem vardır, bunlardan ilki ön budama yöntemidir. Bu yöntemde karar ağacı oluşturulmadan önce tüm öznitelikler tek tek incelenir ve karar ağacı uygun şekilde oluşturulur. Diğer bir yöntem ise sonradan budama yöntemidir. Bu yöntemde oluşturulan karar ağacı incelenir ve oluşturulan modele katkı yapmayan dallar karar ağacından çıkarılır.

Karar ağaçları, yapılarının basit olması, anlaşılabilirliğinin kolay olması ve sınıflandırma problemi için diğer algoritmalara göre nispeten hızlı model oluşturulması sayesinde sınıflandırma problemleri çözümünde kendisine önemli miktarda yer bulmaktadır. Olumlu özelliklerinin yanında nümerik veri setleri için karmaşık bir ağaç yapısı oluşturmaları, test verilerindeki küçük değişikliklere karşı fazla duyarlı olmaları gibi dezavantajlara da sahiptir.

1.11.8. Destek Vektör Makinaları (DVM)

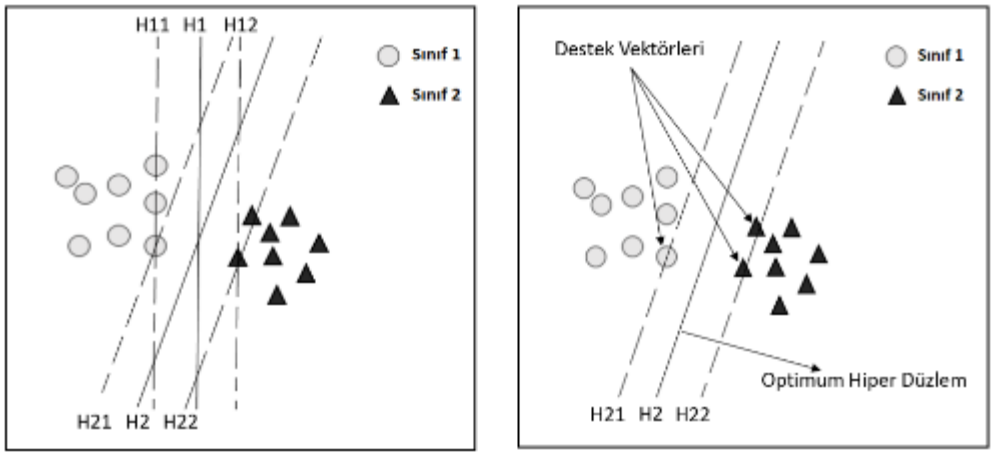
Kullanılan bir diğer sınıflandırma algoritması da Destek Vektör Makinaları (DVM) yöntemidir. Destek vektör makineleri istatistiksel öğrenme teorisi tabanlı bir sınıflandırma algoritmasıdır. Bu yöntem İlk olarak Vapnik ve çalışma arkadaşları tarafından iki sınıflı ve doğrusal olarak ayrılabilen veri setlerini sınıflandırmak için kullanılmıştır. Ancak gerçek dünya problemlerinin birçoğu doğrusal olarak birbirinden ayrılamayan ve ikiden fazla sınıf içeren veri setlerinden oluşmaktadır. Bu durumdan dolayı temel DVM yöntemi geliştirilerek ikiden fazla sınıflı ve doğrusal olarak birbirinden ayrılamayan veriler için de kullanılabilir hale getirilmiştir. Temel olarak DVM yöntemi iki sınıfı en uygun şekilde ayırabilecek hiper düzlemlerin belirlenmesi şeklinde çalışmaktadır. Şekil 10 (a)' da görülen iki sınıflı bir veri setinde iki sınıf arasına birden fazla hiper düzlem çizilebilir. DVM yönteminde amaç iki sınıfın birbirine en yakın olan noktalar arasındaki uzaklığı en büyük değere ulaştıran hiper

düzlemi bulmaktır. Şekil 10 (b)' de birçok hiper düzlem arasından en uygun hiper düzlemin çizimi gösterilmektedir. Şekil 10 (b)' de iki sınıfa ait verilerden en uygun hiper düzleme temas eden verilere destek vektörler denilmektedir. k adet veriden oluşan bir eğitim veri setinde $\{x_i, y_i\}$, i=1,…,k olmak üzere en uygun hiper düzleme ait denklemler (24) ve (25) de verilmektedir.

$$w.x_i + b \geq 1 \;\; her\; y = +1\; için \tag{24}$$

$$w.x_i + b \leq 1 \;\; her\; y = -1\; için \tag{25}$$

Bu denklemlerde $x \in R^N$ şeklindedir ve N boyutlu uzayı, y ise $y \in \{-1, +1\}$ olacak şekilde sınıf etiketlerini, w ağırlık vektörünü (hiper düzlemin normali) ve b ise eğilim değerlerini göstermektedir.



(a) (b)

Şekil 10. a) İki sınıflı bir problem için hiper-düzlemler, (b) Optimum hiper-düzlem ve destek vektörleri.

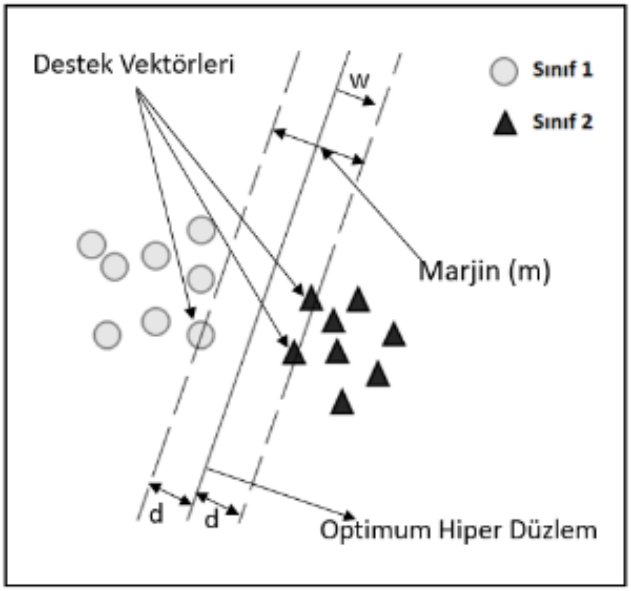
En uygun hiper düzlemin belirlenebilmesi için Şekil 11' de gösterildiği gibi bu hiper düzleme paralel, destek vektörlere temas eden düzlemlerin belirlenmesi gerekir. Belirlenen bu iki hiper düzlem arasındaki uzaklığa marjin denmektedir ve sınıflandırma başarısını artırmak için marjin değerinin en büyük olacak şekilde hiper düzlemlerin belirlenmesi gerekmektedir. Şekil 11' de sınır olarak ifade edilen bu marjin değerinin matematiksel formülü (26)' da verilmektedir.

$$m = 2d = \frac{2}{||w||} = \frac{2}{\sqrt{w_1^2 + w_2^2 + \cdots + w_n^2}} \tag{26}$$

(26) denkleminde m ifadesinin maksimize edilmesi için $\|w\|$ değerinin minimize edilmesi gerekmektedir ve bu minimizasyon işlemi (27) denklemi kullanılarak Lagrange fonksiyonları yardımıyla çözülebilmektedir.

$$L(w, b, \lambda) = \frac{1}{2}||w||^2 - \sum_{i=1}^{N} \lambda_i (y_i (w^T x_i + b) - 1) \tag{27}$$

(27) denkleminde λ, Lagrange çarpanları vektörünü göstermekteyken, $L(w, b, \lambda)$ ise Lagrange fonksiyonunu ifade etmektedir.



Şekil 11. Doğrusal olarak düzlemin belirlenmesi.

Lagrange fonksiyonunun w ve b değerlerine göre kısmi türevler alınarak sıfıra eşitlenmesiyle elde edilen değerler (27) denkleminde yerine konulursa (28) denklemi elde edilmiş olur.

$$L(w, b, \lambda) = \sum_{i=1}^{N} \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j x_i x_j \tag{28}$$

Denklem (28)'de, sıfırdan farklı olan λi değerleri destek vektörlerine (xs) aittir ve xs 'ler denklem (29)'daki eşitliği sağlamaktadır.

$$y_s(x_s.w + b) = 1 \tag{29}$$

Yapılan işlemler sonucu b değeri, denklem (30)'daki gibi ifade edilebilir.

$$b = \frac{1}{N_s} - \sum_{s \in S} \left(a_m a_y x_m . x_s\right) \tag{30}$$

Veri setinin doğrusal olarak ayrılamaması durumunda tanımlanan bir ξ değişkeniyle birlikte doğrusal olarak ayrılmayı önleyen veriler, oluşturulan bir optimizasyon modelinde kullanılarak bu sorunun üstesinden gelinmeye çalışılır. Bu durumda çözülmesi gereken en önemli sorun marjinin olabildiğince büyük yapılması sırasında verilerin hatalı sınıfa karışması durumudur. Belirlenen bir C ceza parametresi ve sınıflandırma hatasını en aza indirecek optimizasyon işlemi ile veriler en uygun şekilde sınıflandırılmaya çalışılır. C parametresi ve ξ değişkenin kullanılmasıyla minimize edilecek olan ifade (31) denkleminde verilmektedir.

$$J(w) = \frac{1}{2}||w||^2 - C\sum_{i=1}^{N} \xi_i \tag{31}$$

Bu denklemin çözümü için geçerli olan kısıtlar ise denklem (32) de verilmektedir.

$$y_i[< w, x_i > + b] \geq 1 - \xi_i, \quad \xi_i \geq 0 \qquad i = 1, \dots, n \tag{32}$$

Doğrusal olarak ayrılamayan verilerin sınıflandırılmasında kullanılan bir diğer yöntem ise çekirdek fonksiyonlarının kullanılarak veri boyutunun artırılmasıdır. Kullanılacak olan bir Φ fonksiyonu yardımıyla öznitelik matrisinin boyutu artırılır, buradaki amaç boyutu artan öznitelik matrisindeki verilerin artık belirlenen bir hiper düzlem ile birbirinden ayrılabilmesidir. Açıklanan bu işleme ait görsel Şekil 12' de verilmektedir (Kavzaoğlu & Çölkesen, 2010).. Matematiksel olarak açıklamak gerekirse; iki boyutlu x=[x_1 x_2] öznitelik

matrisinin (33) ile (38) arasında verilen denklemler yardımıyla boyutu artırılarak yeni bir z=[$\Phi_1(x), \ldots, \Phi_6(x)$] öznitelik matrisi elde edildiği varsayılsın.

$$\Phi_1(x) = 1 \tag{33}$$

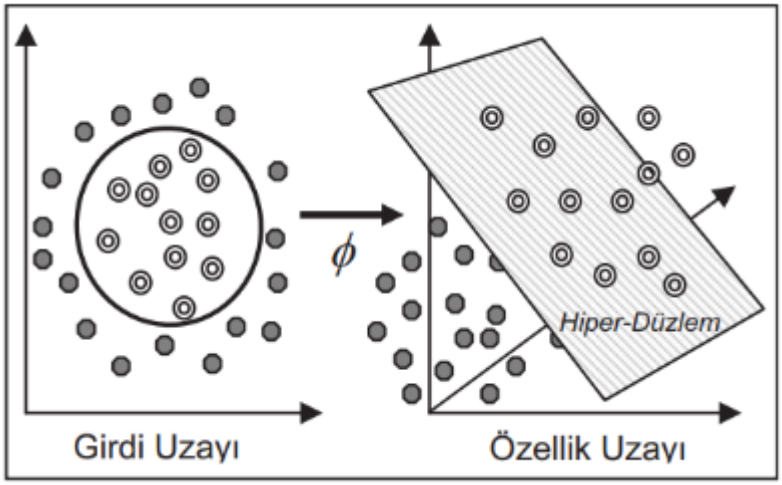
$$\Phi_2(x) = \sqrt{2}\, x_1 \tag{34}$$

$$\Phi_3(x) = \sqrt{2}\, x_2 \tag{35}$$

$$\Phi_4(x) = x_1^2 \tag{36}$$

$$\Phi_5(x) = x_2^2 \tag{37}$$

$$\Phi_1(x) = \sqrt{2}\, x_1 x_2 \tag{38}$$



Şekil 12. Kernel fonksiyonu ile verinin daha yüksek bir boyuta dönüştürülmesi

Kullanılan bu fonksiyonlar sonrasında yeni karar düzlemi (39) denklemiyle ifade edilebilir.

$$d(z) = w^T z + b \tag{39}$$

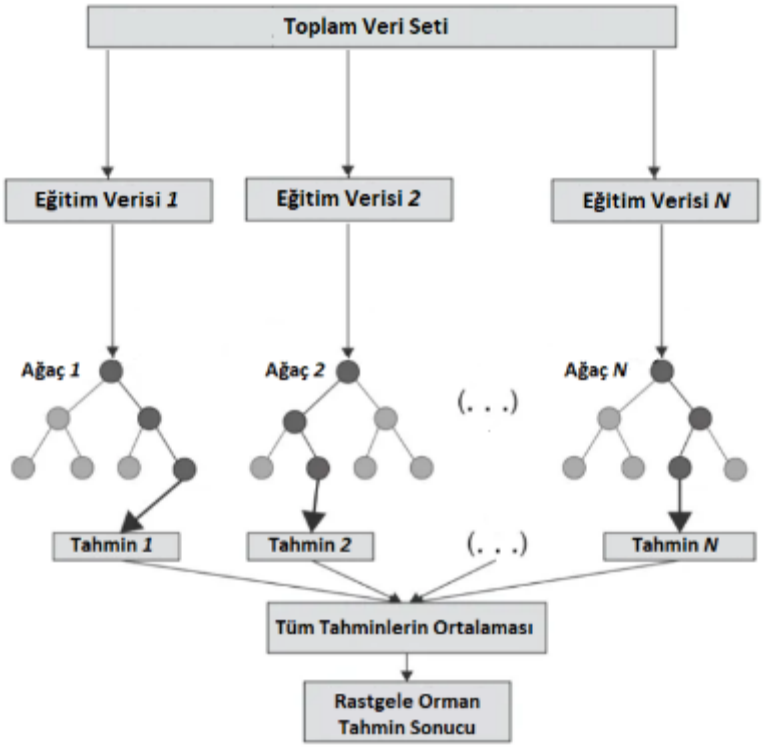
(38) denklemi, daha açık şekilde (40) denkleminde verildiği gibi yazılabilir.

$$f(x) = [w_1 \dots w_6] \begin{bmatrix} 1 \\ \dots \\ \sqrt{2}\, x_1 x_2 \end{bmatrix} + b \tag{40}$$

DVM yöntemi iki sınıflı problemler için geliştirilen bir yöntemdir, ikiden daha fazla sınıflı problemlerin çözülmesi için bire karşı bir (oen versus one) ve bire karşı diğerleri (one versus another) yöntemleri kullanılmaktadır.

1.11.9. Rastgele Orman

Rastgele orman yöntemi Breiman tarafından geliştirilmiş olan, sınıflandırma ve regresyon problemlerinin çözümünde sıklıkla kullanılan bir toplu öğrenme yöntemidir (Breiman, 2001). Kullanılan veri seti eğitim ve test verisi olarak ayrılmakta, eğitim verileri kullanılarak N adet karar ağacı oluşturulmakta, test verileri kullanılarak da oluşturulan ağaçların performansları ölçülmektedir. Rastgele orman yapısının içerisinde bulunan her bir ağaca, bu ağaçların performansına göre belirli ağırlıklar verilmektedir. En yüksek hata değerine sahip ağaç düşük bir katsayıyla ağırlıklandırılır iken, yüksek başarı oranına sahip ağaçlar daha yüksek bir katsayıyla ağırlıklandırılır. Rastgele orman yönteminin genel yapısı Şekil 13' te verilmektedir.



Şekil 13. Rastgele orman yönteminin genel yapısı

Rastgele orman yöntemi regresyon problemlerinde de kullanılmaktadır. Bu problemlerde kullanılırken toplam karesel hata değeri kullanılır ve en düşük toplam karesel hata değerini veren değişken en iyi bölünmeyi sağlayan değişken olarak belirlenmektedir.

Kullanılacak olan rastgele orman yönteminin performansını etkileyen iki yöntem bulunmaktadır. Bu parametreler, her düğümde kullanılacak olan değişken sayısı (m), ve geliştirilecek olan ağaç sayısıdır (n). Bu parametrelerin değerleri kullanılan veri setine bağlı olarak değişebilmektedir. Breiman bu konuda, m parametre değerinin çalışmada kullanılan değişken sayısının karekökü̈ne eşit değerde alınmasının kararlı sonuçlar vereceğini belirtmiştir (Breimann, 2002). Bu çalışmada m ve n çifitinin değerleri deneme yanılma yöntemi kullanılarak sırasıyla 100 ve 30 olarak belirlenmiştir. Bu çalışmada kullanılan rastgele orman algoritmasında bulunan karar ağaçlarında bölünmeyi sağlayan algoritma gini indeksi değerini kullanan CART algoritmasıdır.

1.11.10. Bulanık Mantık ve Bulanıklık Kavramı

Günlük hayatta kullandığımız birçok terim bulanıklık içermektedir. Bir şekli veya cismi tanımlarken bir emir verirken ve daha birçok durumda kullandığımız ifadelerin yapısı bulanıklık içermektedir. Bu bulanık ifadelere örnek vermek gerekirse, sıcak, ılık, biraz fazla, çok fazla, kısa, uzun, bulutlu, güneşli gibi terimler bulanıklık kavramı içermektedir. Günlük hayatta karşılaştığımız bir olayı anlatıyorken veya karar vermemiz gereken bir durum hakkında karar verecek olduğumuz zaman yukarıda birkaç örneğine vermiş olduğumuz bulanıklık içeren yapılar kullanılır. Örneğin kullandığımız araba yavaş gidiyorsa arabanın hızını biraz artırırız veya içtiğimiz herhangi bir içeceğin şeker miktarı az ise biraz şeker ekleyebiliriz. Bu örnekler içerisinde belirsizlik olan durumlarda bireylerin verdiği cevapların bulanıklık içerdiğinin birer örneğidir. Bulanık mantık teorisi ve bulanık mantık kurallarının kullanıldığı bulanık küme teorisi 1965 yılında Lotfi A. Zadeh tarafından “The Theory of Fuzzy Logic and Fuzzy Sets (Bulanık Mantık ve Bulanık Kümeler Kuramı)” makalesi ile ortaya çıkmıştır (Zadeh, 1965). Bulanık mantık yöntemi 1970'li yıllardan sonra daha yoğun olarak kullanılmaya başlanmıştır. Bunun nedeni Lotfi A. Zadeh’ nin bulanık mantığın belirsizlik içeren farklı sistemler üzerinde nasıl uygulanabileceğini gösteren çalışmalarının ortaya çıkmasıdır (Zadeh, 1973)(Zadeh, (1975). İlerleyen yıllarda bulanık mantık yöntemine farklı araştırmacıların da ilgisinin artması sonucu Bulanık mantığın kullanımı önemli ölçüde artmış ve günümüzde de birçok alanda kullanılan bir yöntem olmuştur. Elektrik elektronik

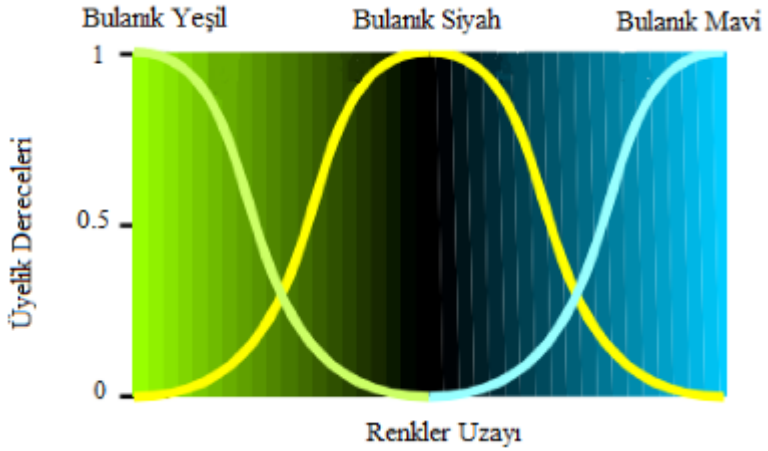
mühendisliği alanında Bulanık mantığın kullanıldığı uygulamalar aşağıdaki gibi verilebilir (Altaş, 1999).

- Otomatik kontrol sistemleri, bu sistemlere örnek olarak robotik sistemler otomasyon sistemleri akıllı denetim sistemleri ve izleme gözetleme sistemleri örnek verilebilir
- Veri işleme depolama yeniden çağırma uzman sistemler ve bilgi tabanlı sistemler.
- Görüntü tanıma sayısal işaret işleme görüntü işleme makine öğrenmesi ve çeşitli veri sınıflandırma uygulamaları
- Optimizasyon sayısal filtreleme fonksiyon optimizasyonu ve eğri uydurma gibi uygulamalar örnek olarak verilebilir.

Bulanık mantık yöntemi hem doğrusal hem de doğrusal olmayan sistemlerde yapılan işlemler konusunda oldukça kullanışlıdır. Günlük hayatta kullanıla gelen sistemlerin hemen hemen hiçbiri doğrusal değildir ve bulanık mantık yöntemi günlük hayatta kullanılan bu sistemlerin analizi konusunda yararlı çözümler ortaya koymaktadır (Altaş, 1999).

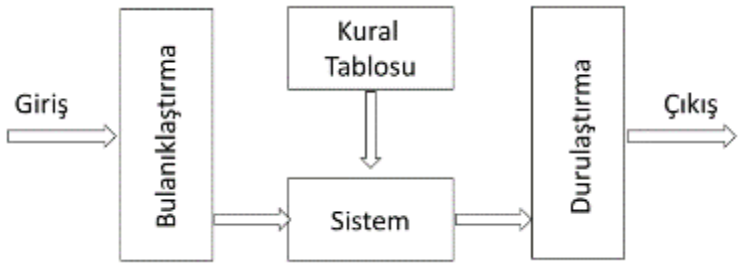
Bulanık mantık yönteminin temel elemanları olan kurallar üyelik fonksiyonları ve sonuca varma işlemleri, üzerinde çalışılan sistem hakkında edinilen bilgilerden türetilen dilsel terimler yardımıyla belirlenir ve üzerinde çalışılan problemin çözülmesi amaçlanır.

Bulanık mantık yönteminde belirsizlik içeren büyüklükleri tanımlamak için bulanık kümeleri ifade eden üyelik fonksiyonları kullanılır. Bulanık kümeler yardımıyla bulanıklaştırılan sayılar insan düşünce ve karar verme mekanizmasında olduğu gibi eğer ise olsun şeklindeki önermeler ve kural yürütme işlemleri ile birlikte yine bulanık bir sonuca dönüştürülür. Bulanık mantık yönteminde uygun işlemlerin yapılması için üzerinde çalışılan uygulama hakkında daha önceden öğrenilmiş ve tecrübe edilmiş bilgiler kullanılır ve kararlar verilir. Bulanık mantık yönteminin temelini bulanık kümeler oluşturmaktadır. Bulanık kümelerin karakterize edilmesi ise üyelik fonksiyonları ile gerçekleştirilir. Bulanık mantık yöntemindeki üyelik fonksiyonları aslında birer bulanık sayı ifade etmektedir. Şekil 14' te verilen örnek incelenerek bulanıklık kavramı daha iyi anlaşılabilir (Altaş, 1999).. Bu şekilde farklı tonlara sahip yeşil siyah ve mavi renkleri renk uzayında gösterilmektedir. Renk uzayının sağ bölgesinden sol bölgesine ilerledikçe önce mavi renkten siyah renge daha sonra ise siyah renkten yeşil renge doğru geçiş yapılmaktadır. Bu geçiş yapılırken öncelikle bölgenin mavi kümesine ait olma derecesi bir başka deyişle üyelik derecesi azalırken siyah bulanık kümesine olan ait olma derecesi artmaktadır. Sonrasında ise siyah bulanık kümesine olan üyelik derecesi azalmaktayken yeşil bulanık kümesine olan üyelik derecesi artmaktadır.



Şekil 14. Yeşil, siyah ve mavi bulanık renk kümeleri

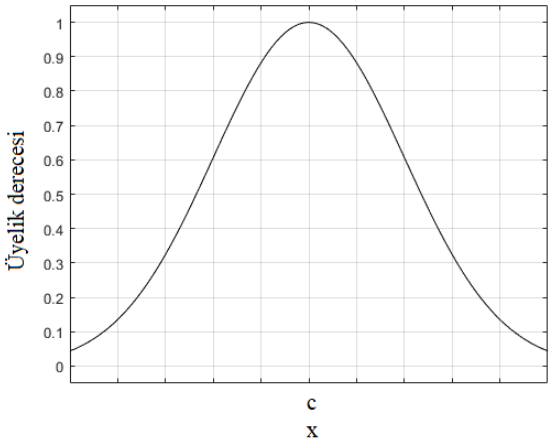
Bulanık sistemlerin genel yapısı Şekil 15 'teki gibi verilebilir.



Şekil 15. Bulanık sistemlerin genel yapısı

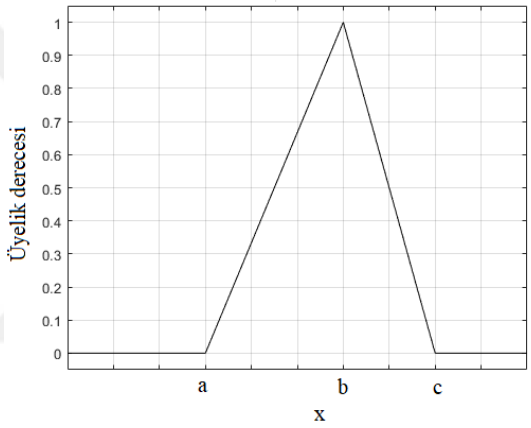
Şekil 15'te verilen bulanık sistemlerin içerdiği arayüzlerin işlevlerini açıklamak gerekirse; sisteme uygulanacak olan kesin girdi değerleri bulanık değerlere dönüştürülür. Bulanık sistemlerde kesin girdi değerleri bulanık kümeler kullanılarak sözel ifadelere dönüştürülmektedir.

Bulanık sistemde kullanılan kümelerin üyelik fonksiyonlarının ve üyelik derecelerinin belirlenmesi için sezgi-tecrübe, çıkarım, açılı bulanık kümeler, mertebeleme, genetik algoritmalar ve yapay sinir ağları gibi algoritmalar kullanılmaktadır. Bu test çalışmasında 5 farklı çeşitte bulanık küme üyelik fonksiyonu kullanılmıştır bu fonksiyonlar Gauss üyelik fonksiyonu, üçgen üyelik fonksiyonu, çan üyelik fonksiyonu, yamuk üyelik fonksiyonu ve pi-şekilli üyelik fonksiyonlarıdır. Kullanılan bu üyelik fonksiyonlarına ilişkin görseller ve bu üyelik fonksiyonlarına ait matematiksel formüller sırasıyla Şekil 16, Şekil 17, Şekil 18, Şekil 19 ve Şekil 20’ verilmektedir.



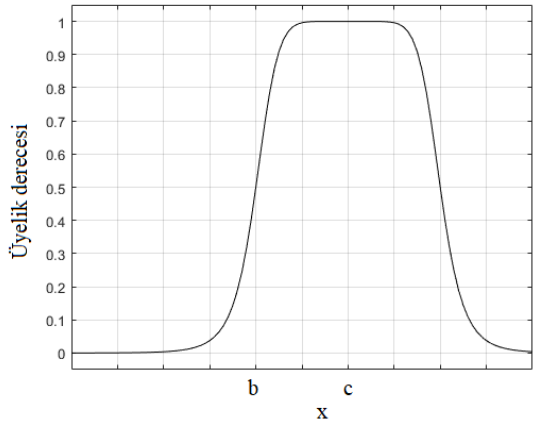
$$f(x;\sigma,c) = e^{\frac{-(x-c)^2}{2\sigma^2}}$$

Şekil 16. Gaus üyelik fonksiyonu genel yapısı



$$f(x;a,b,c) = \begin{cases} 0, & x \le a \\ \frac{x-a}{b-a}, & a \le x \le b \\ \frac{c-x}{c-b}, & b \le x \le c \\ 0, & c \le x \end{cases}$$

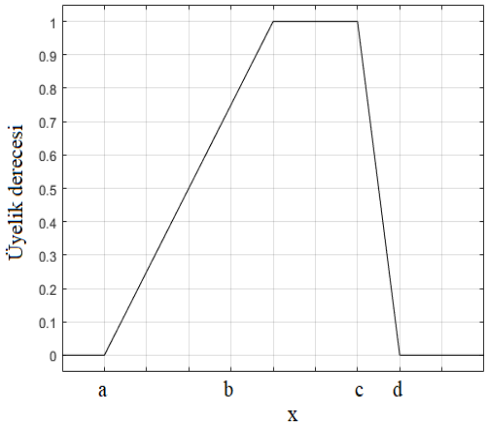
Şekil 17. Üçgen üyelik fonksiyonu genel yapısı



$a=b-c;$

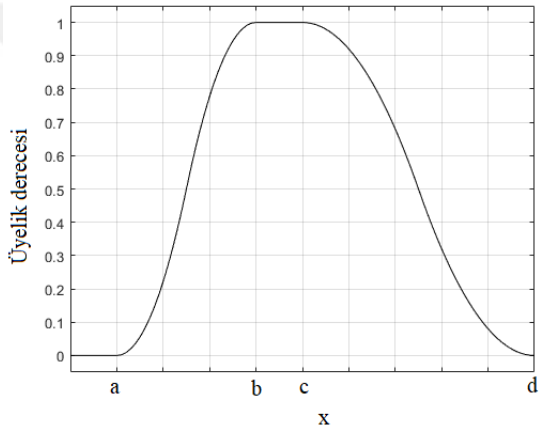
$$f(x;a,b,c) = \frac{1}{1+\left|\frac{x-c}{a}\right|^{2b}}$$

Şekil 18. Çan üyelik fonksiyonu genel yapısı



$$f(x;a,b,c,d)=\max\left(\min\left(\frac{x-a}{b-a},1,\frac{d-x}{d-c}\right),0\right)$$

Şekil 19. Yamuk üyelik fonksiyonu genel yapısı



$$f(x;a,b,c,d)=\begin{cases}0, & x\le a\\ 2\left(\frac{x-a}{b-a}\right)^2, & a\le x\le\frac{a+b}{2}\\ 1-2\left(\frac{x-b}{b-a}\right)^2, & \frac{a+b}{2}\le x\le b\\ 1, & b\le x\le c\\ 1-2\left(\frac{x-c}{d-c}\right)^2, & c\le x\le\frac{c+d}{2}\\ 2\left(\frac{x-d}{d-c}\right)^2, & \frac{c+d}{2}\le x\le d\\ 0, & x\ge d\end{cases}$$

Şekil 20. Pi-şekilli üyelik fonksiyonu genel yapısı

Bulanık sistemlerin diğer bir birimi olan kural işleme biriminde ise sözel ifadelere çevrilmiş olan girdi değişkenlere için bulanık sonuç çıkarımları yapılır. Bu çıkarımlar için sistemle ilgili daha önceden belirlenmiş olan kurallar kullanılır ve sonuç sözel ifadeleri hesaplanır. Bu birimde kullanılan bulanık kurallar "eğer... ise, ... olsun" şeklindedir. Örneğin, "eğer a değeri x ise b değeri y olsun" şeklindedir. Bu açıklamalardan da anlaşılacağı üzere bulanık sonuç çıkarma işlemi 2 bileşenden oluşmaktadır. Bu bileşenlerden ilki kümeleme işlemidir ve bu işlemde kuralların eğer... bölümleri hesaplanır. İkinci işlemi ise düzen bölümüdür ve bu bölümde ... olsun şeklinde kural belirlenir.

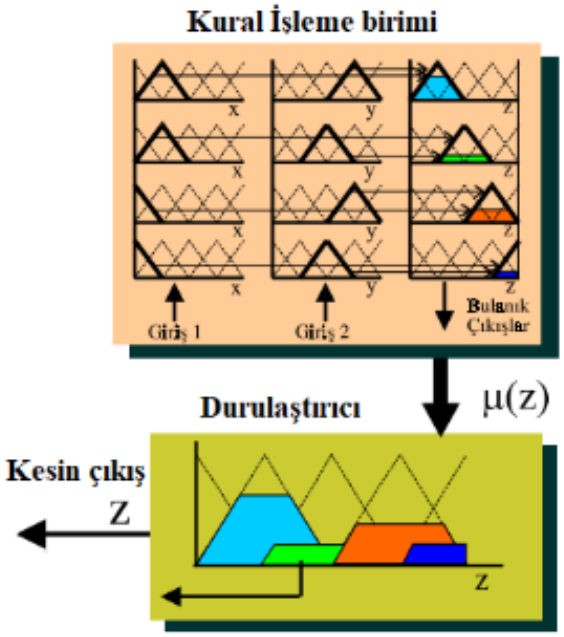
Bu aşamada en önemli konulardan biri kuralların uygun olmasıdır. Kural tablosunun en uygun şekilde belirlenmesi üzerinde çalışılan problemin doğru şekilde çözümünü sağlayacak olan en önemli faktördür. Kural tablosu belirlenmesi için üzerinde çalışılan sistemin uzman bireyler tarafından detaylı olarak en iyi şekilde incelenmesi ve bütün

detaylarına hakim olunması gerekmektedir. Sözel ifadeler kural işleme biriminde işlendikten sonra durulaştırma birimine iletilir. Mühendislik uygulamaları, plan-proje ve tasarımlar gibi pratik uygulamalarda kesin sayısal değerler kullanılmaktadır. Bulanık sistemlerde elde edilmiş olan bulanık değerler durulaştırma biriminde kesin sonuçlar haline dönüştürülür. Bu kesin sonuçların elde edilmesi için yapılan işlemlerin tümüne de durulaştırma denmektedir. Durulaştırma için farklı yöntemler kullanılabilmektedir, bu yöntemlerden en fazla kullanılanları alanların merkezi yöntemi, iki bölge yöntemi, maksimumun ortalaması yöntemi, maksimumun en büyüğü yöntemi, Sugeno bulanık modelleri ve Tsukamato bulanık modelleridir (Maiers&Sherif, 1985). Bu tez çalışmasında yapılan bulanık mantık uygulamasında durulaştırma için alanların merkezi yöntemi kullanılmıştır.

Alanların merkezi yönteminin çalışma prensibi Şekil 21' de görülebilir (Altaş, 1999). Şekil 21’ de gösterilen kesin çıkış ifadesi aşağıdaki (41) denklemi kullanılarak hesaplanmaktadır.

$$\text{Kesin çıkış} = \frac{\sum_{i=1}^{N} \mu_i(z_1) z_i}{\sum_{i=1}^{N} \mu_i(z_1)} \tag{41}$$

(41) denkleminde i, kural numarasını göstermekteyken, N ise toplam kural sayısını göstermektedir.

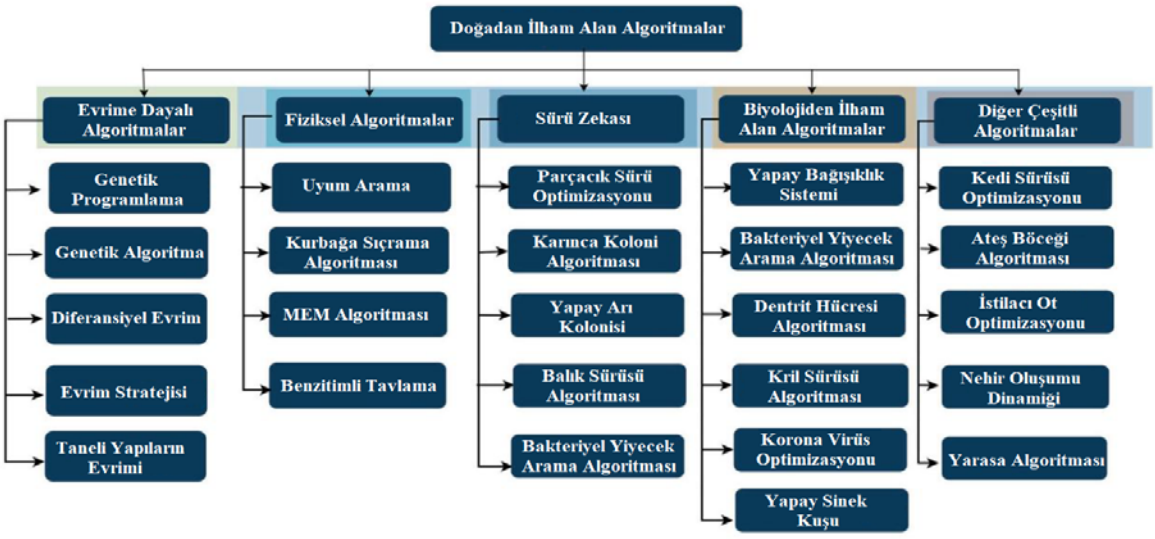


Şekil 21. Alanların merkezi durulaştırma yöntemi akış diyagramı

Bulanık mantık yönteminin başarısını etkileyen en önemli etkenlerden birinin üyelik fonksiyonlarının konumu ve parametreleri olduğu açıklanmıştı. Üyelik fonksiyonlarının uygun şekilde düzenlenmesi BMY' nin daha doğru sonuçlar vererek verilerin daha yüksek başarı oranlarıyla sınıflandırılmasını sağlayacaktır. Doktora çalışmamızda üyelik fonksiyonlarının belirlenmesi için Meta-sezgisel yöntemler içerisinde bulunan beş adet optimizasyon algoritması kullanılmıştır. Meta-sezgisel yöntemlerle ilgli bilgiler aşağıda açıklanmaktadır.

1.11.11. Meta-sezgisel Yöntemler

Meta-sezgisel yöntemler, bir dizi karmaşık gerçek dünya sorununu çözmek için öne çıkan yaklaşımlardan biridir. Bu algoritmalar doğada gözlemlenen büyüleyici davranışlardan ilham almaktadırlar. Geçtiğimiz birkaç yılda, optimizasyona dayalı problemlerdeki artan karmaşıklık, araştırmacıları merkezi olmayan ve kendi kendini organize eden sistemlere odaklanan etkili problem çözme algoritmalarını keşfetmeye motive etmiştir (Sharma&Tripathi, 2022). Meta-sezgisel algoritmalar, fiziksel olayların, biyolojik evrimin ve balık, kuş, karınca, termit vb. gibi canlı varlıkların davranışlarından ilham almaktadırlar. Literatürde bulunan meta-sezgisel algoritmaların sınıflandırılması Şekil 22'



Şekil 22. Meta-sezgisel algoritmaların sınıflandırılması.

de verilmektedir (Sharma&Tripathi, 2022). Bu çalışmada her bir alt başlıktan birer adet optimizasyon algoritması kullanılarak BMY ile sınıflandırma için üyelik fonksiyonları

parametreleri optimize edilmiştir. Kullanılan optimizasyon algoritmalarını isimleri ve detayları aşağıda verilmiştir.

1.11.12. Genetik Algoritma

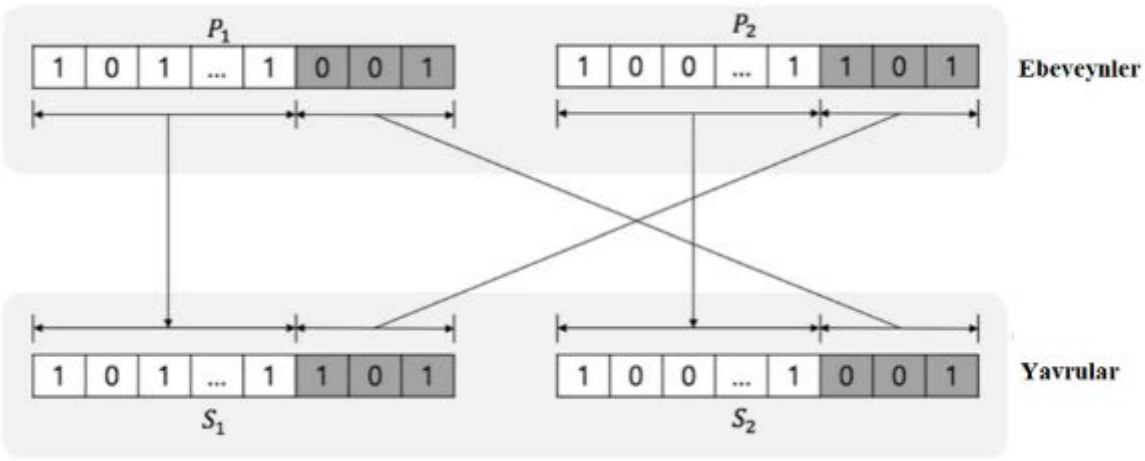
Genetik algoritma (GA), Darwin'in "en güçlü olanın hayatta kalması" teorisinden ilham alan bir optimizasyon algoritmasıdır. GA, doğal evrim sürecini simüle ederek karmaşık sorunları etkili bir şekilde çözebilir. Genel olarak, üzerinde çalışılan problem hesaplama açısından çözülemeyecek kadar karmaşıksa, optimuma yakın bir çözüm elde etmek için bir yöntem olarak GA kullanılabilir. GA, biyolojik çoğalma sürecini taklit eden genetik operatörler tarafından karakterize edilebilir. Bir hesaplama problemi için olası çözümler olan kromozomlar rastgele üretilir ve üretilen bu kromozomlar kademeli olarak dönüştürülerek daha iyi çözümler üretilmesi amaçlanır. Bu süreçte çözüm gen olarak ifade edilebilir ve dönüşüm yoluyla daha iyi bir çözüm oluşturma süreci de evrim olarak adlandırılabilir.

Amaç fonksiyonunun genetik temsili ve tanımı, bir GA sürecinin iki ana gereksinimidir. Genetik temsil, hedef problemin potansiyel çözümlerini (bireyleri) ifade etmenin bir yoludur. Bu durum önemlidir çünkü genetik temsilin sonucu, çaprazlama ve mutasyon gibi tüm GA işlemlerini etkiler; bu nedenle hedef problemin doğası iyi yansıtılabilmelidir. Uygunluk işlevi, simülasyonları optimum tasarım çözümlerine yönlendirmek için kullanılan bir tür amaç işlevidir. Bu fonksiyon, her bir kromozomun performansını ölçer ve bu değerlendirme süreci boyunca GA, problem için en uygun çözümü bulur. GA'da altı aşama dikkate alınır. Bu aşamalar başlatma, uygunluk hesaplaması, seçim, çaprazlama, mutasyon ve sonlandırma koşulu kontrolüdür (Kim&Shi, 2007).

Popülasyon başlatıldıktan sonra, her nesilde her bir kromozomun uygunluğu hesaplanır. Önceden tanımlanmış uygunluk fonksiyonu, iyi çözümleri seçmek için kullanılır. GA sürecinde, uygunluk fonksiyonunun belirlenmesi, modelin performansını ciddi şekilde etkileyebileceğinden çok önemli bir adımdır. Uygunluk fonksiyonunun tanımı hedef problem için uygun değilse, GA yanlış çözüme yakınsayabilir.

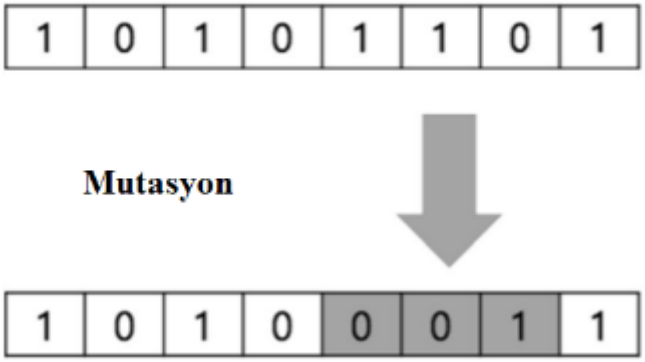
Seçim, üreme fırsatlarını her bir kromozoma tahsis eder. Her çözümün uygunluğunun hesaplanması sürecinde, rekombinasyon işlemi için sadece daha yüksek uygunluk değerlerine sahip çözümler seçilir. Seçimin ana fikri, daha iyi çözümleri belirlemek ve üstün olanların genlerini bir sonraki nesle aktarmasına izin vermektir.

Çaprazlama, GA işlemindeki en önemli aşamalardan biridir. Seçilen kromozomlar, iki ebeveynin genetik bilgilerini birleştirerek yavruları oluşturur. Seçilen kromozomlardan ikisi, dizinin karşılık gelen kısımlarını değiştirir ve yeni aday çözümler oluşturmak için gen kombinasyonlarını değiştirir. Bu işlemin gerçekleşme aşaması Şekil 23' te verilmektedir (Chung & Shin, 2019).



Şekil 23. GA' da çaprazlama işlemi

Mutasyon sürecinde, rastgele seçilen kromozomların Şekil 24 'te gösterildiği gibi tek tek bitler yer değiştirir. Çaprazlama işlemi, tamamen yeni bilgilerin üretilemeyeceği şekilde sınırlıdır. Bununla birlikte, mutasyon işlemiyle bu sınırlamanın üstesinden gelinebilir, çünkü mutasyon işlemi bir kromozomun her bir bitini tamamen yeni bir değere dönüştürür. Bu işlemin amacı, popülasyondaki çeşitliliği korumak ve yerel optimum problemini önlemektir.



Şekil 24. GA' da mutasyon işlemi

Jenerasyon süreci boyunca yeni üretilen kromozomlar, sonlandırma koşuluna ulaşılıp ulaşılmadığını kontrol etmek için değerlendirilir. GA süreci, popülasyon birleştiğinde sona erer. Ancak, sonlandırma koşullarından en az biri sağlanana kadar tüm süreç yinelenir (Chung&Shin, 2019).

1.11.13. Parçacık Sürü Optimizasyonu

Sürü sistemleri olarak adlandırılan bazı karmaşık sistemler, zor problemleri verimli ve güvenilir bir şekilde çözebilen kullanışlı bir yeniden hesaplama yöntemleri kaynağı olabilmektedir. Sürüler doğadaki sorunları çözdüğünde, yetenekleri genellikle sürü zekasına atfedilir; bunlardan en iyi bilinen örnekler, termitler, arılar ve karıncalar gibi sosyal böceklerin kolonileridir. Son yıllarda, sürü zekasının bazı biçimlerinin altında yatan hesaplama ilkelerini tanımlamanın, soyutlamanın, kullanmanın ve bunları bilimsel-endüstriyel amaçlar için kullanmanın mümkün olduğu kanıtlanmıştır. Bu şekilde türetilmiş en iyi tekniklerden biri de parçacık sürüsü optimizasyonudur (Kennedy&Eberhart, 2001).

Kuş sürülerinden ve balık sürülerinden ilham alan Parçacık Sürü optimizasyonunda (PSO), bir dizi basit varlık (parçacıklar), bir problemin veya fonksiyonun parametre uzayına yerleştirilir ve her biri mevcut konumunda üzerinde çalışılan problemin uygunluğunu değerlendirir. Daha sonra her parçacık, kendi uygunluk değerleri geçmişinin bazı yönlerini, sürünün bir veya daha fazla üyesinin değerleriyle birleştirerek parametre uzayındaki hareketini belirler. Bir parçacığın etkileşime girebileceği sürünün üyelerine sosyal komşuluk denir ve bu sosyal komşulukların tamamı birlikte PSO sosyal ağını oluşturur. N boyutlu bir problem için, her parçacığın konumu ve hızı, N bileşenli (her boyut için bir tane) bir vektör olarak temsil edilebilir. Başlangıç hız vektörü $v = (v_1, \dots, v_N)$ şeklinde verilen hız vektörü her bir bileşen için (42) denklemindeki gibi verilir.

$$v_i(t+1) = wv_i(t) + \Psi_1 R_1 \left(x_{s_i} - x_i(t)\right) + \Psi_2 R_2 \left(x_{p_i} - x_i(t)\right) \tag{42}$$

Bu denklemde x_{s_i} parçacığın komşuları tarafından ziyaret edilen en iyi noktanın i'inci bileşeni , $x_i(t)$ parçacığın mevcut konumunun i'inci bileşeni, x_{p_i} kişisel en iyi değerin i'inci bileşeni, R_1 ve R_2 iki bağımsız rasgele değişkendir. [0, 1] aralığında düzgün bir şekilde dağılmış olan ω, atalet ağırlığı olarak bilinen bir sabittir. Ψ_1 ve Ψ_2 ise hızlanma katsayıları olarak adlandırılır ve sosyal etkileşim ile sosyal bilişin göreli oranını kontrol eden iki sabittir.

PSO da hız vektörünün belirlenmesinin ardından her bir parçacığın konumu (43) denklemi kullanılarak her adımda güncellenir.

$$x_i(t+1) = x_i(t) + v_i(t+1) \tag{43}$$

Bir sonraki yineleme, tüm parçacıklar yeni konumlarına taşındıktan sonra gerçekleşir. Sonunda, bir bütün olarak sürü, toplu olarak yiyecek arayan bir kuş sürüsü gibi, muhtemelen en iyi konuma yaklaşmaktadır.

1.11.14. Benzetimli Tavlama

Benzetimli Tavlama (BET) algoritması, optimizasyon problemlerinin çözümünde en çok tercih edilen sezgisel yöntemlerden biridir. Bu yöntem Kirkpatrick ve ark. tarafından metal işlemenin tavlama prosedüründen ilham alınarak geliştirilmiştir (Kirkpatrick vd., 1983). Tavlama işlemi, kütlenin potansiyel enerjisinin en aza indirildiği metal parçacıklarının optimum moleküler düzenlemelerini tanımlar ve metallerin yüksek ısıya maruz kaldıktan sonra kademeli olarak soğutulmasını ifade eder. Genel olarak BT algoritması, metallerin tavlama işlemini taklit eden değişken sıcaklık parametresine göre yinelemeli bir hareket benimser.

Basit bir optimizasyon algoritması, etki alanındaki mevcut ve komşu nokta ile çalışan amaç fonksiyonlarının çıktılarını yinelemeli olarak karşılaştırır. Böylece komşu nokta mevcut olandan daha iyi sonuç üretirse, sonraki yineleme için temel çözüm olarak kaydedilir. Aksi takdirde, algoritma, daha iyi sonuçlar için daha geniş etki alanını aramadan prosedürü sonlandırır. Bu nedenle, algoritma yerel minimum veya maksimuma takılmaya eğilimlidir. Bunun yerine BET algoritması, tavlama işlemi için soğutma prosedürü ve Metropolis kriteri olan iki yinelemeli döngüyü birleştirerek bu soruna etkili bir çözüm önerir. Daha iyi açıklamak gerekirse, minimizasyon problemini ele alalım. Parametreleri $x_i = \{x_1, x_2, \ldots x_n\}$ olan bir $f(x_i)$ amaç fonksiyonunu ele alalım. Eğer $f(x_{i+1}) < f(x_i)$ ise x_{i+1} noktası yeni bir uygun nokta olarak ele alınır. Eğer aksi durum söz konusu ise bir *w* ifadesi tanımlamak gerekir. Bu w ifadesi, $w = \exp[-\{f(x_{i+1}) - f(x_i)\}/T_c]$ şeklinde tanımlanır. Bu denklemde T_c ifadesi geçerli sıcaklık parametresidir. *w* ifadesinin tanımlanmasının ardından bir de [0-1] aralığında değerler alan bir *s* değeri üretilir. Eğer *w* > *s* durumu mevcut ise x_{i+1} yeni bir çözüm noktası olarak kabul edilebilir. Aksi durumda önceki adıma geri

dönülüp farklı bir s değeri üretilir. Dolayısıyla, Metropolis kriteri, amaç fonksiyonunun yörüngesi potansiyel yerel minimum noktasında yakınsasa bile mevcut adımın hareketine bir dereceye kadar izin verir. Diğer taraftan Metropolis algoritması sabit bir sıcaklık için çözüm önermektedir. Böylece, daha büyük T_c değerleri için algoritma daha geniş arama alanı gerektirir. Bu nedenle, bu durum küresel minimuma ulaşma olasılığını yükseltir. Bunun yanı sıra, algoritmanın yinelemeli hareketi rasgele başlatıldığından, global minimumları atlayabilir veya uç noktadan hassas olmayan bir yaklaşım benimseyebilir. Aksine, daha küçük T_c değerleri için daha küçük arama alanı gerektirir ve bu durum yerel minimumlara hapsolmaya neden olabilir. Bu olumsuz durumu ortadan kaldırmak için BET, sıcaklık parametresini ve çözüm noktasını değiştirmek için iç içe döngüler içeren yinelemeli bir çözüm sunar. BET algoritmasının hareketi, iç döngü için yinelemeyi yürütmek için daha büyük bir sıcaklık değeri ile başlar ve hemen, mevcut iç döngüdeki en iyi amaç fonksiyonuna götüren nokta, yeni aday çözüm olarak atanır. Ardından, sıcaklığın artırılması ve başlangıç noktasının güncellenmesi ile dış döngü çalıştırılır. Bu yinelemeli süreç, sıcaklığın en düşük sınırına ulaşana veya önceden belirlenmiş sayıda yinelemeyi gerçekleştirene kadar devam eder.

1.11.15. İstilacı Yabani Ot Optimizasyon Algoritması

Tarımda ekin alanlarını zararlı ve istenmeyen türlerden tamamen temizlemek için yapılan tüm çabalara rağmen istilacı yabani otların hayatta kalma ve kolonileşme yeteneği oldukça iyidir. İlgili yabani bitki türleri, ürünler arasındaki boşluklara yayılarak ekili alanları hızla işgal edebilir. Kullanılmayan bu boşluklardaki kaynaklar, her yabani ot tarafından olgunluğa ulaşmak ve tohumlama yoluyla taze yabani otlar üretmek için kullanılır. Her biri genç bir ota dönüşecek tohumların sayısı, çiçekli otun tohum verme olgunluğuna ulaşması ile belirlenir. Başka bir deyişle, çiçekli bir ot ne kadar ekin alanına uyum sağlar ve ekilmemiş alanlardaki kaynakları kullanırsa, o kadar çok tohum üretir. Üretilen tohumlar, yeni yabani otlara dönüşmek için çiçekli otlarının etrafına rastgele dağılır. Öte yandan, ekim alanındaki kaynakların sınırlı olması, yabancı ot sayısının belirli bir sayıda kalmasına neden olur. Kaynakların izin verdiği maksimum yabani ot popülasyonuna ulaştıktan sonra, daha güçlü bireylerin daha yüksek üreme ve hayatta kalma yetenekleri nedeniyle, daha zayıf olan yabani otların ilgili alanlarda üremeleri ve hatta hayatta kalmaları imkansız hale gelir. Ekin alanındaki sınırlı kaynakları kullanmak için istilacı yabani otlar arasındaki mücadele,

yalnızca zayıf yabani otların ortadan kaldırılmasına değil, aynı zamanda daha güçlü üyelerin daha da gelişmesine de yol açar (Şimşir&Taşpınar, 2020). Bu fırsatçı ve hızla gelişen istilacı yabani otların yukarıda belirtilen kolonizasyon davranışından ilham alan Mehrabian ve Lucas, 2006 yılında istilacı yabani ot optimizasyonu (İYO) adı verilen güçlü bir algoritma geliştirdiler. Standart İYO algoritması, istilacı yabani otların doğal kolonizasyon mekanizmasını taklit edecek şekilde tasarlanmıştır. Bu amaçla ilgili kolonizasyon mekanizmasına ait özellikler aşağıdaki şekilde dört temel kural olarak idealize edilmiştir:

Nüfus başlatma: Başlangıç popülasyonu, çözüm vektörlerini temsil eden belirli sayıda yabancı otun, çözüm uzayına karşılık gelen alana rastgele belirlenmiş konumlarına saçılmasıyla oluşturulur. D boyutlu bir çözüm uzayındaki yabancı ot konumları (44) gibi tanımlanabilir:

$$X_i^d = [X_i^1, X_i^2, \dots, X_i^D], i = 1, 2, \dots, W_0 \tag{44}$$

Bu denklemde i, populasyon üyelerinin indeksini gösterir ve W_0 başlangıç popülasyon büyüklüğünü belirtir.

Çoğalma: Popülasyonda bulunan istilacı yabani otların her birine yeni tohumların üretilmesi yoluyla üreme şansı verilir. Bir yabancı otun daha fazla üreme şansı, ilgili yabani ot tarafından üretilecek tohum sayısını belirleyen uygunluk değerine bağlıdır. Bir yabani otun uygunluk değeri ne kadar iyiyse, önceden tanımlanmış bir aralıkta [S_{min}, S_{max}] o kadar fazla tohum üretebilir; burada S_{min} ve S_{max} , popülasyondaki herhangi bir yabani ot tarafından üretilecek minimum ve maksimum tohum sayısını belirtir. Uygunluk değerine göre çekirdek sayısının belirlenmesi aşağıdaki eşitlikle yapılır:

$$S_i = floor[S_{min} + \frac{Q_i - Q_{worst}}{Q_{best} - Q_{worst}} (S_{max} - S_{min})] \tag{45}$$

(45) denkleminde S_i, i'inci çözüm tarafından üretilen tohumların sayısını, Q_i, i'inci çözümün uygunluk değerini, Q_{best} ve Q_{worst} sırasıyla yabancı ot popülasyonundaki en iyi ve en kötü uygunluk değerlerini gösterir. "floor(•)", içindeki değerden küçük veya ona eşit en büyük tamsayıyı veren bir operatördür.

Mekansal Dağılım: Bu aşamada, bir önceki aşamada üretilen tohumlar arama uzayına rastgele şekilde dağıtılır. Her biri farklı bir yabancı ot tarafından üretilen tohum gruplarının ortalama sıfır civarında normal dağılım oluşturduğunu ebeveyn yabani otlar tohumlarını

etraflarına saçarlar. i' inci çözüm vektörü X_i^d tarafından üretilen tohumların konumları aşağıdaki işlemle belirlenir.

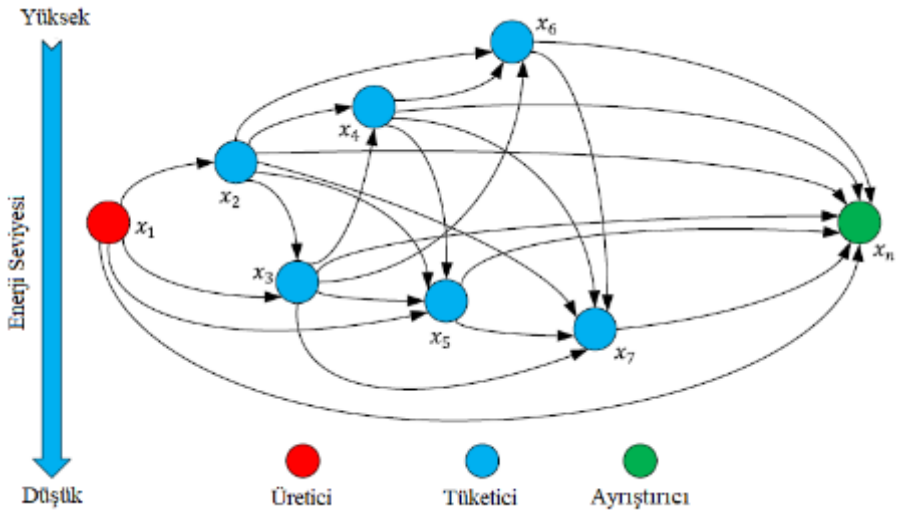
$$Y_{ij}^d = X_i^d + N(0, \sigma_{it}^2), d = 1, 2, \dots, D; j = 1, 2, \dots, S_i \quad (46)$$

Bu denklemde Y_{ij}^d, j'inci tohumun d'inci boyutunu temsil eder. $N(0, \sigma_{it}^2)$ ise σ_{it} standart sapma değerine sahip, sıfır ortalamalı rastgele sayılar üreten bir fonksiyonu temsil etmektedir.

Rekabetçi Dışlama: Yabani ot kolonisinin boyutu, Wmax ile belirtilen maksimum popülasyon büyüklüğünü aştığında, hem ebeveyn yabani otlar hem de yavruları, özellikleri bakımından birlikte değerlendirilir. Değerlendirilen bireyler arasından düşük rekabet değerine sahip otlar ortadan kaldırılarak çoğalma şansı daha fazla olan yabani otlara öncelik tanınır.

1.11.16. Yapay Ekosistem Optimizasyonu

Yapay ekosistem optimizasyon algoritması (YEO) temel olarak canlı organizmalar arasında türlerin istikrarını korumaya yardımcı olan enerji aktarım mekanizmasına dayanan bir algoritmadır. Bunu yapmak için üretim, tüketim ve ayrıştırma olarak adlandırılan üç operatör çözüme ulaşmak için kullanılır.Şekil 25, üretici, tüketici ve ayrıştırıcıdan oluşan yapay bir ekosistemdeki enerji akışını göstermektedir(İzci vd., 2021).



Şekil 25. YEO' da örnek bir ekosistem

Üretme: YEO'da popülasyonun en kötü bireyi üretici tarafından temsil edilmektedir. Bu nedenle diğer bireylerin başka bölgeleri aramasına yardımcı olabilmesi için arama uzayının alt ve üst sınırları dikkate alınarak en iyi bireye göre güncellenmesi gerekmektedir. Üretim operatörü aracılığıyla, rastgele oluşturulmuş ($x_{rastgele}$) bireyler güncellenerek mevcut bireyler arasında en iyi (x_n) bireyinin güncellenmesi sağlanmaktadır Üretim operatörünün matematiksel gösterimi (47) ve (48) denklemlerindeki gibi verilebilir:

$$x_2(t+1) = (1-a)x_n(t) + a * x_{rastgele}(t) \tag{47}$$

$$a = (1 - t\ /\ T)r_1 \tag{48}$$

burada n, popülasyon sayısını T, maksimum iterasyon sayısını göstermektedir.

Tüketim: Üretim işleminde üreticilerin üretimi tamamlandıktan sonra tüketim aşamasına geçilir. Düşük enerji seviyesine sahip bir tüketici ve üretici daha yüksek enerji seviyesine sahip herhangi bir tüketici tarafından tüketilebilir. (49) denklemi kullanılarak ekosistem içerisindeki arayışı artırmak için Levy uçuşu rastgele yürüyüş ismiyle tanımlı bir tüketim faktörü (*C*) ifadesi üretilir.

$$C = \frac{1}{2}\frac{v_1}{|v_2|} \tag{49}$$

$$v_1 \sim N(0,1), v_2 \sim N(0,1) \tag{50}$$

(62) denklemine $N(0,1)$, ortalama ve standart sapma sırasıyla 0 ve 1'e eşit olacak şekilde normal bir dağılımı temsil eder. Farklı tüketici türleri tarafından farklı stratejiler benimsenir. Bir tüketici, otobur olarak rastgele seçilmesi durumunda üreticiyi yiyecektir. Otçul tüketim davranışı, (51) denklemindeki gibi matematiksel olarak modellenmiştir.

$$x_i(t+1) = x_i(t) + C * \big(x_i(t) - x_1(t)\big), i \in [2, \dots, n] \tag{51}$$

Bir tüketici, rastgele bir etobur olarak seçilirse, yalnızca daha yüksek enerji düzeyine sahip başka bir tüketiciyi yer. Bir etobur davranışı (52) denklemiyle modellenebilir.

$$x_i(t+1) = x_i(t) + C * \big(x_i(t) - x_1(t)\big), i \in [2, \dots, n] \tag{51}$$

$$j = randi([2i - 1]) \tag{52}$$

Son iki davranıştan farklı olarak, daha yüksek enerji seviyesine sahip bir tüketici veya bir üretici, rastgele bir omnivor olarak seçilirse, tüketici tarafından rastgele yenebilir. Bu davranışın matematiksel formu şu şekilde ifade edilir:

$$\begin{gathered} x_i(t+1) = C * \Big(r_2 * \big(x_i(t) - x_1(t)\big)\Big) + (1 - r_2)\Big(x_i(t) - x_j(t)\Big), \\ i \in [3, \dots, n] \\ j = randi([2i - 1]) \end{gathered} \tag{53}$$

(53) denkleminde r_2, [0 -1] aralığında rastgele bir sayıdır. Bir arama bireyinin konumu, tüketim operatörünü kullanan bir popülasyondaki rastgele seçilen veya en kötü bireylere göre güncellenir. Dolayısıyla bu, algoritmanın global bir arama yapmasına izin verir.

Ayrıştırma: Ayrıştırma işlemi uygun şekilde çalışan bir ekosisteme sahip olmak için çok önemli bir süreçtir. Ayrıştırıcı, üreticinin büyümesi için gerekli besinleri sağlamak üzere popülasyondaki her ölen bireyin kalıntılarını kimyasal olarak parçalar. Ayrışma faktörü D ile birlikte ağırlık katsayıları h ve e bu davranışı matematiksel olarak modellemek için kullanılmaktadır. Bu parametreler, x_i'nin (i. birey) konumunun x_n'nin (ayırıcının konumu) konumuna göre güncellenmesine yardımcı olur. Ayrıca, her bireyin bir sonraki pozisyonunun ayrıştırıcı (en iyi birey) etrafında yayılmasına izin verilir. Ayrıştırma ifadesinin matematiksel formülü aşağıdaki denklemlerle verilir:

$$x_i(t+1) = x_n(t) + D * \big(e * x_n(t) - h * x_i(t)\big), \quad i \in [1, \dots, n] \tag{54}$$

$$xD = 3u, \quad u \sim N(0,1) \tag{55}$$

$$e = r_3.randi(|\,1\;2\,| - 1 \tag{56}$$

$$h = 2.r_3 - 1 \tag{57}$$

1.11.17. k-Kat Çapraz Doğrulama ve Başarı Ölçümleri

k- kat çapraz doğrulama yöntemi üzerinde çalışılan problemin doğruluğunun belirlenmesinde literatürde sıklıkla kullanılan yöntemlerden biridir. Bu yöntemde veri seti A ile temsil edilecek olursa, öncelikle tüm veri seti a1 a2 a3 şeklinde k adet parçaya ayrılır. Ayrılan bu veri parçalarında olabildiğince eşit sayıda veri bulunmasına dikkat edilir. Bu yöntem kullanılırken k adet parçaya bölünmüş veri setinden her seferinde 1 adet veri seti test verisi diğerleri eğitim veri seti olacak şekilde sınıflandırma yapılır.

1.11.18. Literatürde Bulunan Çalışmalar

Literatürde bulunan çalışmalar incelendiğinde e-burunların oldukça fazla uygulama alanına sahip oldukları görülebilir ve bu alanların başında yiyecek içecek sektörü geldiği söylenebilir. Örneğin kırmızı et kalitesinin, tazeliğinin ve içerisine herhangi bir malzeme karıştırıldığının belirlenmesi için elektronik burunlar kullanılabilmektedir (Wojnowski vd.,2017). Kırmızı et uygulamalarından farklı olarak balık tazeliğinin belirlenmesi için yine e-burunlar kullanılmaktadır (Atasoy vd, 2015). Kırmızı et ve balık yanında kanatlı hayvan etlerinin raf ömrünün belirlenmesi konusunda da e-burun çalışmalarına rastlanmaktadır(Haddi vd, 2015). Farklı sıcaklıklarda ve farklı sürelerde saklanan tavuk etinin tazeliğinin ve üzerinde bulunan mikroorganizma yoğunluğunun belirlenmesi için yine e-burunların kullanıldığı çalışmalara literatürde rastlanmaktadır (Timsorn vd.,2016).

Et ile ilgili olan çalışmalar yanında kahve ile ilgili e-burun uygulamalarına da literatürde rastlanmaktadır. Bu konuyla ilgili kahve çekirdeklerinin hangi düzeyde kavrulması gerektiği e-burun ile yapılan çalışmalarla optimize edilmeye çalışılmıştır (Anwar vd., 2007).

Çikolata sektöründe üretim aşamasında özellikle çikolata aromasının analizi önemli bir yer tutmaktadır. Literatürde bulunan çalışmalar incelendiğinde hem üretim aşamasında aroma analizi hem de çikolatanın tazeliği ve raf ömrü ile ilgili e-burun kullanılarak gerçekleştirilen çalışmalar bulunmaktadır (Zan & Kerr, 2018). Kakao çekirdeklerinin hangi seviyede kavrulması gerektiği ve bu kavurma işleminin çikolata kalitesine etkisi konusunda e-burun ile ilgili çalışmalar bulunmaktadır (Valdez & Gutierez, 2016).

Alkol ve alkollü içeceklerin incelenmesi de e-burun çalışmaları arasında önemli bir yer tutmaktadır. Damıtılmış likörlerin tanımlanması, pirinç şaraplarının sınıflandırılması, sentetik şarap örneklerinin tanımlanması, biraların içeriklerinde bulunan aromalara göre

sınıflandırılması ayrıca alkollü ve alkollü olmayan biraların ayırt edilmesi konularında e-burunların kullanıldığı çalışmalar bulunmaktadır (Shi vd., 2008) (Macias vd., 2013) (Sanchez vd., 2018) (Wei vd., 2017) .

Ülkemizde oldukça fazla tüketilen içeceklerden olan siyah çay ile ilgili litratürde e-burunların kullanıldığı çalışmalar bulunmaktadır. Farklı üretim süreçlerinden geçen siyah çayların kalitelerindeki farkların tespit edilmesi ve yeşil çay kalitesinin belirlenmesi konusunda literatürde e-burun uygulamalarına rastlanmaktadır (Yu vd., 2009)(Dutta vd.,2018).

Önemli miktarda tüketilen içeceklerden biri olan kahve ile ilgili de e-burun uygulamaları bulunmaktadır. Farklı ülkelerden farklı kahve çeşitlerinin belirlenmesi, kahvelerin içerdikleri aromalara göre sınıflandırılması, kahve çekirdeğinin kavrulması sürecinin izlenmesi ve kavurma süresinin ürüne etkisi gibi uygulamalarda e-burunlar kullanıldığı görülmektedir (Bona, 2011)(Makimori&Bona,2019).

E-burunların kendilerine uygulama alanı bulduğu ürünlerden birisi de zeytinyağıdır. Zeytinyağı kalitesinin ve kökeninin belirlenmesi, yağların uzun süre kullanılması ve saklanma koşullarının yağın kalite ve aromasına etkisi, farklı bitkilere ait yağların ayırt edilmesi, zeytinyağlarının aromalarına göre sınıflandırılması gibi bir çok uygulamada e-burunlar kullanılmaktadır (Choe&Min, 2007)(Anwar vd., 2016)

Süt ürünleri konusunda e-burun ile yapılan çalışmalarda sütün içerisinde bulunan asit oranı, protein miktarı, kül ve kazein miktarının tespit edildiği çalışmalara rastlanmaktadır. Ayrıca sütün bozulduğunun tespit edilmesi ve içeriğinde herhangi bir hastalık bulunup bulunmadığı da e-burunlar ile tespit edilebilmektedir (Lima vd.,2018)(Anand%Sridhar, 2018).

Su kalitesinin kontrolü ve denetlenmesi, suyun içeriğinde herhangi bir mikroorganizmanın ve kirleticilerin varlığının tespit edilmesi, atık su ve temiz suyun sınıflandırılması, atık suların temizlendikten sonra kalitelerinin tespit edilmesi için yine e-burunların kullanıldığı çalışmalara literatürde rastlanmaktadır (Palasuek vd., 2015)(Rodrigez vd., 2018).

E-burunların kullanıldığı diğer bir alan da tarım ve ormancılıktır. Bu konuda tarım bilimi, bahçecilik, botanik, biyokimyasal yöntemler, pestisit tespiti, istila tespiti, bitki fizyolojisi, bitki patolojisi ve ortam izleme gibi birçok alanda e-burunların uygulamaları bulunmaktadır (Wilson, 2013). Meyve kalitesinin ve olgunluğunun tespiti için yapılan çalışmalar içerisinde özellikle muz meyvesinin olgunluğunun tespitine yönelik çalışmalara

literatürde rastlanmaktadır (Chen vd., 2018). Kivi meyvesinin olgunluk seviyesinin tespiti, Fuji elmasının hasar seviyesinin belirlenmesi, farklı sebzelerin karıştırılmasıyla oluşturulan sebze çorbasındaki Escherichia coli. bakteri varlığının belirlenmesi gibi çalışmalarda e-burunlar kendilerine yer bulmaktadırlar (James vd., 2013)(Ren vd., 2018). Bunların dışında patateslerde oluşan enfeksiyonun tespiti, domateslerde oluşan yaprak bitleri ve beyaz sineklerin tespiti, tütün ürünlerindeki alkaloid seviyesinin belirlenmesi gibi konularda e-burunlar kullanılmaktadır (Cui vd.,2018)(Lin&Zhang,2016).

E-burun uygulamalarının yoğun olarak kullanıldığı önemli alanlardan biri de tıp ve insan sağlığı alanıdır. Sağlık alanında da e-burunlar farklı hastalıkların tespiti için kullanılmaktadır. Örneğin astım hastalığı konusunda literatürde bulunan çalışmalar incelendiğinde farklı e-burunlar kullanılarak farklı hastalık seviyesinde bulunan hastalardan ve sağlıklı gönüllülerden alınan nefes örnekleriyle bu hastalığa ilişkin koku izi tabanı elde edilmeye çalışılmıştır. Yine yapılan çalışmalar içinde astım hastaları ile kronik obstrüktif akciğer hastaları birbirlerinden ayırt edilmeye çalışılmıştır (Fens vd.,2009).

Kanser hastalığı ile ilgili yapılan çalışmalar incelendiğinde, akciğer kanserinin nefes analizi ile tespiti, baş ve boyun kanseri tespiti, bağırsak kanseri tespiti gibi çalışmalarda e-burunların kullanıldığı görülebilir (Wong vd., 2018)(Leunis vd., 2014). Literatürde kanser hastalığı ile yapılan çalışmalara ilişkin e-burun içerikli uygulamalar sonraki bölümlerde daha detaylı örnekler verilmiştir.

Tüberküloz hastalığının tespiti için e-burun ile yapılan çalışmalar arasında tüberküloz kültürlerinin sınıflandırılması ve tüberküloz hastalığına sahip bireylerin tespit edilmesine yönelik çalışmalar bulunmaktadır (Fend vd., 2006)(Brunis vd., 2013).

Bu verilen hastalıkların dışında sinüzit hastalığının tespiti (Mohamed vd, 2003), kistik fibroz hastalığının bulunduğu hastaların sağlıklı bireylerden ayrılması (Enderby vd., 2009), sigara kullanan ve kullanmayan bireylerin nefesleri kullanılarak tespit edilmesi (Cheng vd., 2009), yasa dışı ilaç kullanımının insan nefesinde oluşturduğu değişikliklere bağlı olarak belirlenmesi (Haddi vd., 2011) ve uzay araçlarında yolculuk yapan bilim astronotların sağlık durumlarının gözlemlenmesi için e-burunlar kullanılmaktadır (Straume vd., 2013).

E-burunların kullanıldığı bir diğer uygulama alanı da iç ve dış ortam hava kalitesinin izlenmesidir. İç ortam hava kalitesinin kontrol edilmesi, ortamlarda bulunan gazları tespit edilerek sınıflandırılması, belirli kuruluşların etrafındaki hava kalitesinin incelenmesi gibi

uygulamalarda e-burunların kullanımlarına rastlanmaktadır (Jasinski vd., 2018)(Ismail vd., 2018).

E-burunların kolay taşınabilir olması, güç tüketimlerinin fazla olmaması, fazla yer kaplamamaları, ayırt ediciliklerinin fazla olması bu cihazların güvenlik uygulamalarında da kullanılmalarını sağlamaktadır. Özellikle patlayıcı maddelerin tespitine yönelik uygulamalarda e-burunlar kendilerine yer bulabilmektedirler (Sekhar vd., 2010)(Wang, 2007).

Akciğer kanseri hastalığının nefes analizi ile belirlenmesi konusunda literatürde e-burun ile gerçekleştirilen önemli çalışmalara rastlanmaktadır. Tirzïte ve çalışma arkadaşlarının CyraNose 320 elektronik burun cihazını kullandığı çalışmada 223 sağlıklı ve 252 akciğer kanseri olan hastadan nefes örnekleri alınmıştır. Sensör verilerini ön işlemden geçirmeden ham veri olarak kullanmışlardır. Veri sınıflandırıcı olarak Lojistik Regresyon analizinin kullanıldığı çalışmada birinci evre akciğer kanseri hastalara ilişkin %91 özgüllük değerine ulaşmışlardır (Tırzite vd, 2018). Gasparri ve çalışma arkadaşları ise yaptıkları çalışmada Kuvars Kristal Mikrobalans (KKM) sensörlerden oluşan bir elektronik burun kullanmışlardır. Çalışmaya 76 sağlıklı ve 70 akciğer kanseri hasta olmak üzere 146 gönüllü katılmıştır. Bu çalışmada da sensör verileri ön işlemden geçirilmeden ham veri olarak kullanılmıştır. Kısmi En Küçük Kareler Ayrıştırma analizinin sınıflandırıcı olarak kullanıldığı çalışmada 81% duyarlılık değerine ulaşılmıştır (Gasparri vd., 2016). Farklı evrelerde 43 akciğer kanseri hasta ve 58 sağlıklı gönüllünün katıldığı çalışmada Blatt ve çalışma arkadaşları Metal Oksit Yarıiletken (MOY) sensörlerden oluşan elektronik burun kullanmışlardır. Araştırmacılar bu çalışmada veri boyutu azaltma olarak Temel Bileşen Analizi (TBA) ve parametrik olmayan Doğrusal Ayrıştırma Analizi (DAA) yöntemleri kullanılmıştır. Sınıflandırma algoritması olarak k-En Yakın Komşu (k-EYK), Yapay Sinir Ağları (YSA), doğrusal ve karesel ayrıştırma fonksiyonu tabanlı sınıflandırıcılar kullanılmıştır. Bu çalışma sonunda araştırmacılar 92,6% doğruluk değeri elde etmişlerdir (Blatt vd., 2007). Li ve çalışma arkadaşları 9 MOY, 3 Elektrokimyasal, bir adet katalitik yanmalı ve bir adet ısıl gaz sensörü kullanarak gerçekleştirdikleri elektronik burun ile deneyler gerçekleştirmişlerdir. Çalışmaya 24 akciğer kanseri hasta, 5 farklı solunum yolu hastalığı bulunan gönüllü ile 10 sigara kullanan sağlıklı, 13 sigara kullanmayan sağlıklı gönüllü olmak üzere toplam 52 gönüllü katılmıştır. Deneyler sonucu elde edilen verilerin boyutu TBA, DDA, Doğrusal Yerleştirme (DY), Bölgesel Doğrusal Yerleştirme (BDY) ve t-Dağıtımlı Stokastik Komşu Yerleştirme (t-DSKY) yöntemleri kullanılmıştır. Bulanık k-

EYK algoritması ve Destek Vektör Makinası (DVM) sınıflandırıcılarının kullanılarak yapılan sınıflandırma işlemi sonucunda 91,59% doğruluk ile 91,6% duyarlılık değeri elde edilmiştir (Li vd., 2017). Mazzone ve çalışma arkadaşları 92 akciğer kanseri hasta ve 137 sağlıklı olmak üzere toplam 229 gönüllünün katıldığı çalışmalarında kolorimeterik sensör dizini içeren bir sistem kullanmışlardır. Akciğer kanseri gönüllülerle sağlıklı gönüllüleri birbirinden ayırmayı amaçlayan bu çalışmada 81,1% doğruluk değeri elde edilmiştir (Mazzone vd., 2012). Van der Goor ve çalışma arkadaşları 145 gönüllünün katıldığı çalışmalarında akciğer kanseri hastası bireylerle iyi huylu tümörlü bireylere ait verileri ayırt etmeye çalışmışlardır. Aeonose marka hazır elektronik burun cihazıyla gerçekleştirilen deneyler sonucunda elde edilen veriler YSA algoritmasını kullanılarak sınıflandırılmıştır. Sınıflandırma sonucunda 83% duyarlılık ve 84% özgüllük değerine ulaşılmıştır (Van de Goor vd., 2018). Huang ve çalışma arkadaşları akciğer kanseri tespiti için yaptıkları çalışmada algılayıcı sensör olarak karbon nanotüplerden oluşan bir sensör dizisi kullanmışlardır. Bu çalışmaya akciğer kanseri olan 56 gönüllü ile 188 sağlıklı birey katılmıştır. Veri sınıflandırma için DDA ve DVM algoritmalarının kullanıldığı bu çalışmada 85,4% ile 92,7% aralığında değişen doğruluk değerleri elde edilmiştir (Huang vd., 2018). Literatürde e-burun ile ilgili araştırmalar yapıldığında farklı kanser türlerinin incelendiği önemli çalışmalara rastlanmaktadır (Baldini vd., 2020). Bu çalışmalar araştırmacıların e-burun ile kanser tespiti konusu üzerinde çalışmalar yapmaya devam ettiklerini göstermektedir.

2. YAPILAN ÇALIŞMALAR

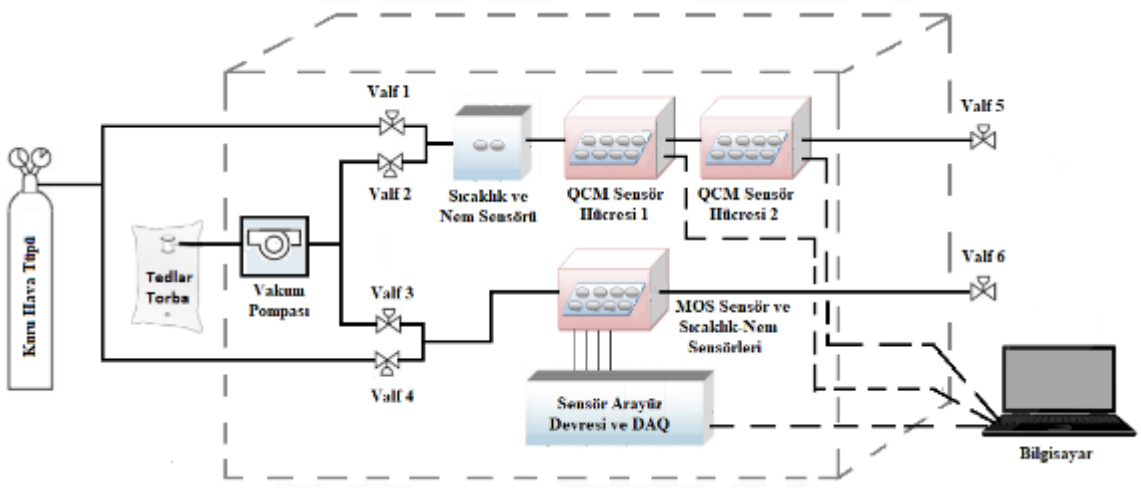
Literatürde bulunan, e-burun kullanılarak akciğer kanseri tespiti ile ilgili çalışmalar incelendiğinde, çoğu çalışmanın sadece bir tip gaz sensörünü içerdiği açıkça görülmektedir (Scheepers vd., 2022). Çalışmamızda MOS ve QCM sensörleri birlikte kullanılarak hem iletkenlik hem de frekans bilgisi elde edilmiştir. Bu çalışmada, elde edilen bu iki bilginin kullanılmasıyla akciğer kanserinin nefes yoluyla daha başarılı şekilde tespit edilmesi amaçlanmaktadır. Bu tez kapsamında yapılan çalışmalar aşağıdaki gibi sıralanabilir.

- Deneylerin gerçekleştirildiği e-burun devresi kuruldu ve gönüllülerden alınan nefes örnekleriyle deneyler gerçekleştirildi.
- Sensörlerden elde edilen verilerin daha kolay yorumlanabilmesi için belirli işaret işleme yöntemleri kullanıldı.
- Sensörlerden elde edilen verilerden nefes örneklerini en başarılı şekilde sınıflandırılmasını sağlayacak öznitelikler çıkarıldı.
- MOY ve QCM sensörlerden elde edilen veriler hem ayrı ayrı hem de birlikte kullanılarak sınıflandırma performansına etkileri incelendi.
- Veri sınıflandırma işlemi iki sınıflı (Akciğer kanseri – Sağlıklı gönüllüler) ve üç sınıflı (Akciğer kanseri – Sigara kullanan sağlıklı gönüllüler- Sigara kullanmayan sağlıklı gönüllüler) olacak şekilde gerçekleştirilerek sistemin performansı incelendi.
- MOY ve QCM sensörlerin birlikte kullanılmasıyla sınıflandırma başarısının arttığı kullanılan veri seti için kanıtlandı.

  Tez çalışması boyunca yapılan çalışmaların içerikleri hakkındaki detayları bilgiler aşağıda verilmektedir.

2.1. Elektronik Burun Deney Düzeneği

Bu çalışma boyunca nefes analizlerinin gerçekleştirildiği elektronik burun devresinin blok diyagramı Şekil 26'da verilmektedir. Geliştirilen deney düzeneği temel anlamda 5 adet bileşen içermektedir. Bu bileşenler; kuru hava tüpü, teflon borular, vakum pompası, solenoid valfler, QCM sensör hücresi, MOS sensör hücresi, sensör arayüz devresi, röle kartı, analog-dijital veri elde etme kartı ve bilgisayardır. Bu bileşenler ve görevleri sırasıyla aşağıda açıklanmaktadır.



Şekil 26. Geliştirilen elektronik burun devresinin blok diyagramı

2.1.1. Kuru Hava

Çalışma boyunca yapılan bütün deneylerin hem öncesinde hem sonrasında tüm sistem içeriği 21% oranında Oksijen ve 79% oranında Nitrojenden oluşan kuru hava ile temizlenmiştir. Sistemde gaz akışını sağlayan teflon boruları da içerecek şekilde sensörlerin ve tüm sistemin temizlenmesi sensörlerden alınan verilerin kararlı ve güvenilir olmasını sağlamıştır.

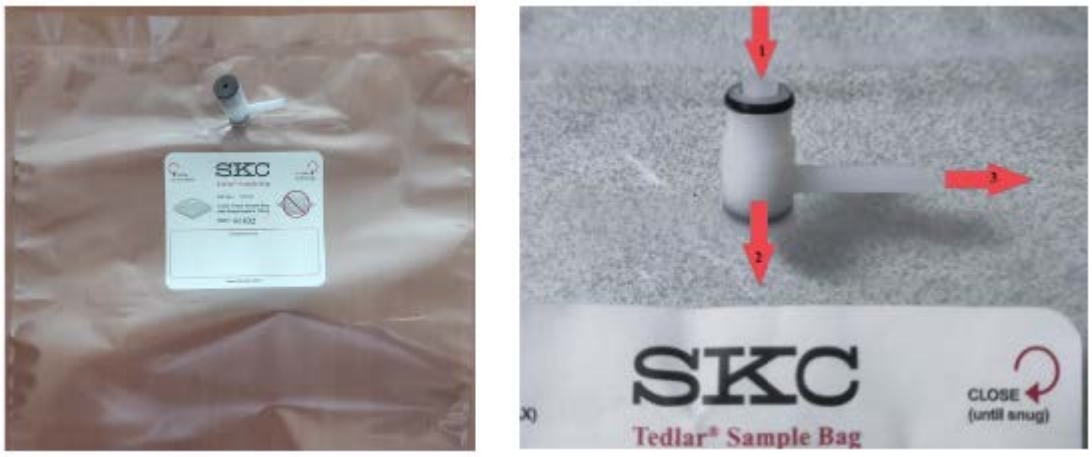
2.1.2. Teflon Borular

Teflon borular deneyler esnasında hem kuru havanın hem de gönüllülerden toplanan nefes örneklerinin uygun şekilde ve uygun yerlere iletilmesi için kullanılmıştır. Teflon boruların çoğu kimyasalla tepkimeye girmemesi ve koku moleküllerini üzerinde tutmaması, bir önceki deneyden üzerlerinde istenmeyen koku moleküllerinin kalmamasını sağlamaktadır. Çalışmada kullanılan teflon boruların dış çapı ve iç çapı sırasıyla 0.25 inç ve 0.17 inçtir.

2.1.3. Tedlar Torba

Deneylere katılan bireylerin nefesleri 5 litre hacimli Tedlar torbalar (CEL Scientific, Cerritos, CA, USA) kullanılarak toplanmıştır. Tedlar torbalar içerden ve dışardan gaz kaçaklarına izin vermediğinden dolayı bireylerden alınan nefes örneklerinin içeriğinde herhangi bir değişiklik olmadan deneyler gerçekleştirilebilmektedir. Her bir gönüllüye ait

tedlar torba sadece tek sefer kullanılmıştır. Kullanılan Tedlar torbalara ait genel görsel ve polipropilen başlığa ilişkin görsel Şekil 27'de verilmektedir.



(a) (b)

Şekil 27. Çalışmada kullanılan Tedlar torba (a) ve polipropilen başlık detayı (b)

Tedlar torbalarda bulunan polipropilen başlıkta 1 numaralı girişten gönüllüler nefeslerini üflemektedir. Eğer 3 numaralı çıkış kapalı tutulursa nefes örnekleri 2 numaralı kısımdan tedlar torba içerisine dolmaktadır. Ancak 3 numaralı çıkış açık bırakıldığı durumda 1 girişinden gelen nefes örnekleri tedlar torbaya girmeden 3 numaralı çıkıştan dışarı çıkmaktadır.

2.1.4. Vakum Pompası

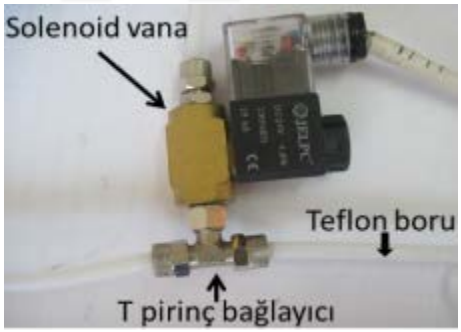
Nefes örneklerinin sensörlere iletilmesi için 12 Volt doğru akım ile çalışan vakum pompası kullanılmıştır. Sistemde kullanılan vakum pompasına uygulanan sabit besleme gerilimi sayesinde nefes örnekleri tüm deneyler boyunca sensör haznelerine aynı hızlarda aktarılmıştır. Vakum pompasının besleme gerilimi elektronik burun sisteminin kurulumu aşamasında belirlenmiştir. Bu aşamada sensör haznelerinin ve tedlar torbaların hacimleri göz önünde bulundurularak nefes örnekleri 3,6 litre/min akış hızı ile sensörlere ulaştırılmıştır. Bu çalışmada kullanılan vakum pompası Şekil 28'de verilmektedir.



Şekil 28. Çalışmada kullanılan vakum pompası

2.1.5. Solenoid Valf

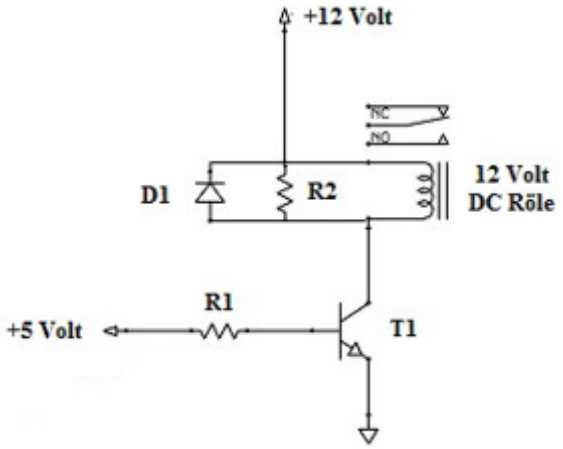
Yapılan deneylerde, nefes örneklerinin ve kuru havanın uygun şekilde yönlendirilmesi için 6 adet solenoid valf kullanılmıştır. Elektriksel çalışma değerleri 24V (DC) ve 4,8 W olan JELPC marka (JELPC,Ningbo, Zhejiang, Çin) vanalara ait görsel Şekil 29' da verilmiştir.



Şekil 29. Çalışmada kullanılan solenoid valf ve bağlantıları

2.1.6. Kontrol Kartı

Çalışmamızda kullanılan kontrol kartı için belirlediğimiz devre Şekil 30' da verilmektedir. Veri elde etme kartımızın sayısal çıkışlarından +5 Volt (DC) Şekil 30' da gösterildiği şekilde T1 transistörüne uygulandığında röle bulunduğu pozisyonu değiştirecek ve istenilen valfe +24 Volt (DC) aktarılabilecektir.



Şekil 30. Kontrol devresinde kullanılan elektronik devre

Şekil 30’ da verilen devre tek bir kontrol sinyali içermektedir. Çalışmamızda 6 adet valf ve 1 adet vakum pompası kontrol edildiğinden dolayı tasarlanan devre, içerisinde Şekil 30’da verilen devreden 10 adet olacak şekilde tasarlanmıştır. Devrede kullanılan elemanlara uygulanacak gerilim ve çekecek oldukları akım değerleri hesaplanarak eleman değerleri Tablo 4’ te verilmektedir.

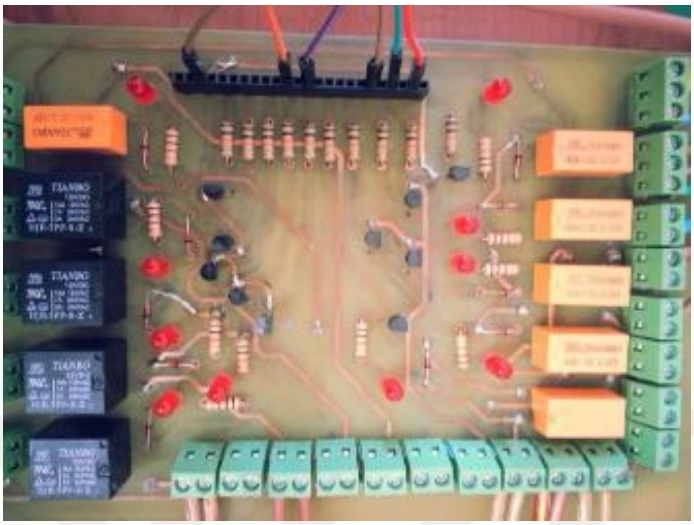
Tablo 4. Devrede kullanılan devre elemanlarının değerleri ve modelleri

Devre Elemanları	**Değerleri ve Modelleri**
R1	10kΩ
R2	1kΩ
D1	1N4128
T1	BC548

Belirlenen devre türü ve devre eleman değerleri kullanılarak öncelikle devre, deneme düzeneğinde gerçekleştirildi ve denemeler yapıldı. Bakır plaka üzerine kurulacak devre için bilgisayar programı yardımıyla kontrol devresinin bakır plaka üzerinde oluşturulacak çift taraflı şekli oluşturuldu ve bakır plaka üzerine baskısı yapıldı.

Devre elemanlarının bakır plaka üzerine lehimlenerek gerekli testlerin yapılması sonucunda elde edilen kontrol kartı devresine ilişkin görsel Şekil 31’ de verilmektedir. Devrede kullanılan valflerin istenen sırada ve sürede açık ve kapalı olması için gerekli olan +5 Volt (DC) işaret National Instruments firmasının NI USB-6212 veri elde etme kartının

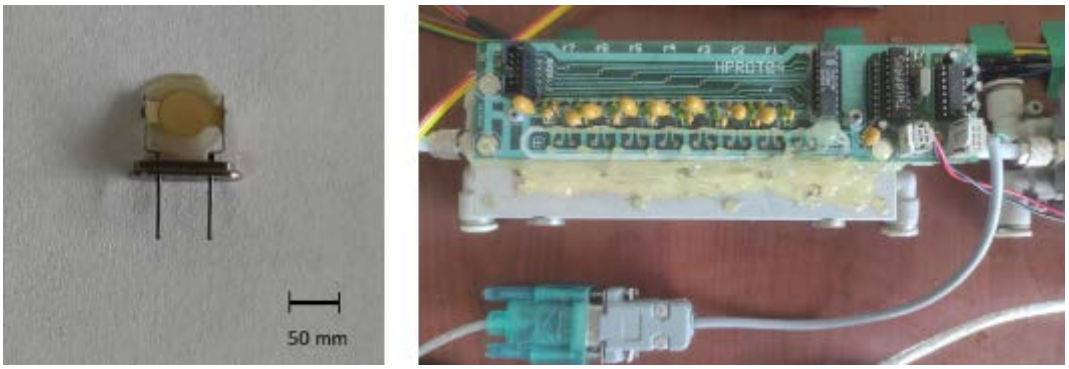
sayısal çıkışları kullanılarak elde edilmiştir. Kullanılan bu veri elde etmek kartı Matlab 2015b yazılımı kullanılarak programlanmıştır.



Şekil 31. Hazırlanan kontrol kartının fotoğrafı

2.1.7. QCM Sensörler ve QCM Sensör Hücresi

Çalışmamızda kullanılan KKM sensörler TÜBİTAK Marmara Araştırma Merkezi, Malzeme Enstitüsü tarafından çalışmamıza destek amaçlı ve bedelsiz olarak gönderilmiştir. KKM sensörlerin yerleştirildiği sensör hücresi ise yurtiçi bir firmadan satın alınmıştır. Çalışmamızda kullanılan KKM sensörlerin şekline ve KKM sensör hücresine ait görsel Şekil 32’ de verilmektedir.



(a) (b)

Şekil 32. Çalışmada kullanılan (a) KKM sensörlerin yapısı (b) KKM sensör hücresi

TÜBİTAK Marmara Araştırma Merkezi, Malzeme Enstitüsü tarafından 42 adet farklı KKM sensör gönderilmiştir, çalışmamızın ilk aşamasında hasta ve sağlıklı gönüllülerden alınan nefes örnekleriyle yapılan deneyler sonucunda kullanılacak olan 14 KKM sensöre karar verilmiştir. Bu KKM sensörlerin frekans değişiminin ölçümü, her birinin içerisinde 7 adet KKM sensörünün yerleştirilebildiği iki adet hücre kullanılmıştır. Her hücrede 7 adet sensör yuvası bulunmaktadır ve bu sayede 7 adet farklı KKM sensörünün tepkileri gözlenebilmektedir. Kullanılan iki KKM sensör hücresinden toplamda 14 adet KKM sensör frekans değişimi gözlenebilmektedir.

2.1.8. MOY Sensörler ve MOY Sensör Haznesi

Bu çalışmada kullanılan ikinci çeşit sensörler MOY tipi sensörlerdir. Çalışmamızda kullanılan MOY sensörler Figaro firmasının üretimi olan ticari tip sensörlerdir. Figaro gaz sensörleri CO, $NH_{3,}$ ve H_2S gibi indirgen gazlara karşı hassas olmasının yanı sıra organik bileşiklerin uçucu bileşenlerine, kimyasal çözücülere, yiyecek-içeceklere ve çeşitli alkollere karşı da hassastırlar.

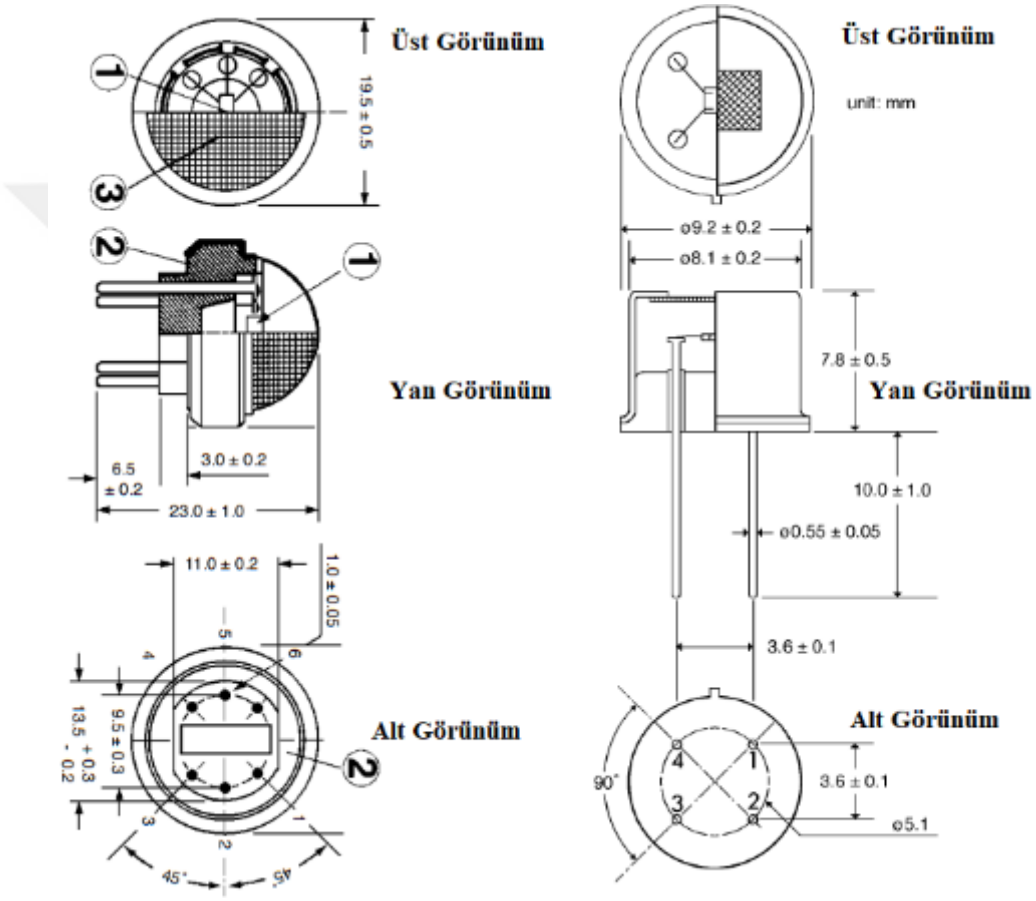
Literatürde bulunan akciğer kanseri ve elektronik burun uygulamaların incelenmesi sonucunda çalışmamızda TGS 813, TGS 816, TGS 826, TGS 832, TGS 2602, TGS 2610, TGS 2612, TGS 2620 sensörleri kullanılmıştır. Kullanılan MOS sensörlere ait hedef gazlar Tablo 5' te verilmektedir.

Tablo 5. Çalışmada kullanılan MOY sensörler ve bu sensörlere ait hedef gazlar

Sensör İsimleri	**Hedef Gaz**
TGS 813	Karbon Monoksit, Metanol, Etanol, Propan, İsobütan, Hidrojen
TGS 816	Karbon Monoksit, Metan, Etan, Propan, İsobütan, Hidrojen
TGS 826	İsobütan, Hidrojen, Amonyak, Etanol
TGS 832	R-12, R134, Etanol, R-22
TGS 2602	Hidrojen, Amonyak, Etanol, Hidrojen Sülfit, Toluen
TGS 2610	Etanol, Hidrojen, Metan, İso-Bütan, İso-Propan
TGS 2612	Etanol, Metan, İso-Bütan
TGS 2620	Metan, Karbon Monoksit,

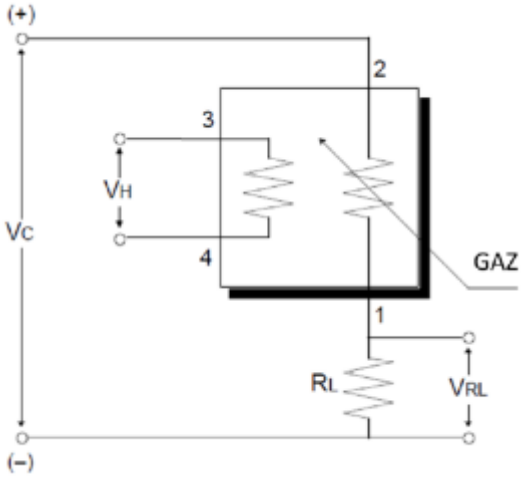
MOY gaz sensörleri etkileşimde bulundukları gazlarla kimyasal tepkimeye girebilmeleri için yaklaşık 400C° seviyesinde bir sıcaklığa ihtiyaç duyarlar. Bu sıcaklığın sağlanması için de sensörlerin harici bir kaynak ile beslenmesi gerekmektedir. Kullanılan

MOY gaz sensörlerinden sensör cevabı gerilim bölücü bir devre oluşturularak elde edilir. Bu gerilim bölücü devresini oluşturmak için sensörlere seri bağlanan bir R_L direnci kullanılır ve sensör direncindeki değişimin R_L direnci üzerinde oluşturduğu gerilim değişimi algılanarak bilgisayara kaydedilir. Bu doktora çalışmasında kullanılan TGS 8xx ve TGS 2xxx serisi sensörlere ilişkin teknik resimler sırasıyla Şekil 33 (a) ve (b) de verilmektedir. Kullanılan MOY gaz sensörlerinin elektriksel eşdeğer devreleri Şekil 34 ’te verilmektedir.



Şekil 33. MOY gaz sensörlerine ait teknik çizimler (a) TGS8xx serisi (b) TGS2xxx serisi

Şekil 34’ te verilen elektriksel eşdeğer devrede V_C, devre gerilimini, V_H sensör ısıtıcı gerilimini ve R_L sensöre seri bağlı yük direncini göstermektedir. Çalışmada kullanılan sensör çeşitlerine ait V_C, V_H ve R_L değerleri Tablo 6’ da verilmektedir.



Şekil 34. MOY gaz sensörlerine ilişkin elektriksel eşdeğer devre

Tablo 6. Çalışmada kullanılan MOY gaz sensörlerine ait teknik bilgiler

	TGS8xx	**TGS2xxx**
$\mathbf{V_C}$	24 V	5 V
$\mathbf{V_H}$	5 V	5 V
$\mathbf{R_L}$	Min. 450 Ω	Min. 450 Ω
$\mathbf{I_H}$	130 mA	55 mA

MOY tipi gaz sensörlerine seri bağlanan yük dirençlerinin belirlenmesi için gerçekleştirilen e-burun devresinin kurulum aşamasında deneyler yapılmış ve en uygun direnç değerleri Tablo 7 ’teki gibi elde edilmiştir.

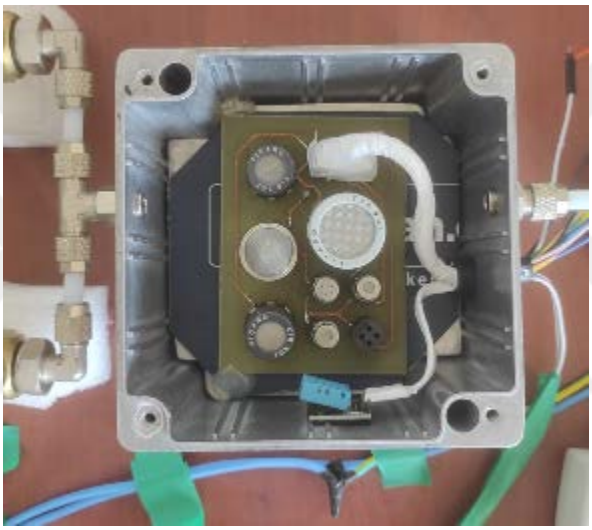
Tablo 7. Kullanılan MOY tipi sensörlere bağlı olan yük dirençleri

TGS 813	TGS 816	TGS 826	TGS 832	TGS 2602	TGS 2610	TGS 2612	TGS 2620
6k Ω	1k Ω	2k Ω	3k Ω	1k Ω	4.7k Ω	2k Ω	2k Ω

2.1.9. MOY (Metal Oksit Yarıiletken) Sensör haznesinin ve Bu Sensörlere Bağlı Dirençlerin Yerleştirileceği kartların Oluşturulması

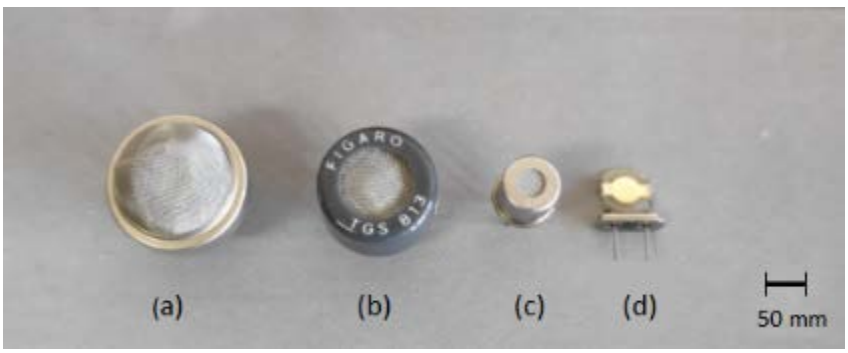
Bu çalışmada MOY sensörlerin yerleştirilmesi için alüminyum sensör haznesi kullanılmıştır. Sensör haznesinin kapağı üst kısımdan vida ile kapatılmaktadır. MOY

sensörler sensör haznesi içerisinde alt kısma yerleştirilerek koku moleküllerinin sensörlerin üst kısımlarından geçmesi sağlanmıştır. Sensör haznesi olarak düzgün yüzeyli alüminyum malzeme kullanılmasının nedenlerinden biri de yüzeyine az miktarda koku molekülünün yapışması ve daha kolay temizlenebilmesidir. Alüminyum haznenin karşılıklı iki yanına açılan deliğe yerleştirilen pirinç bağlayıcılarla sensör haznesine hava giriş çıkışı sağlanmaktadır. Ayrıca sensör haznesinin bir yanından açılan bir delikten sensörlere besleme ve ısıtma gerilimi uygulamak için gerekli olan bağlantı kabloları hazne içerisine aktarılmıştır. Çalışmamızda kullanılan MOY sensör haznesinin sensörlerin de içerisinde bulunduğu durumdaki fotoğrafı Şekil 35' te verilmektedir.



Şekil 35. Çalışmada kullanılan MOY sensör haznesi

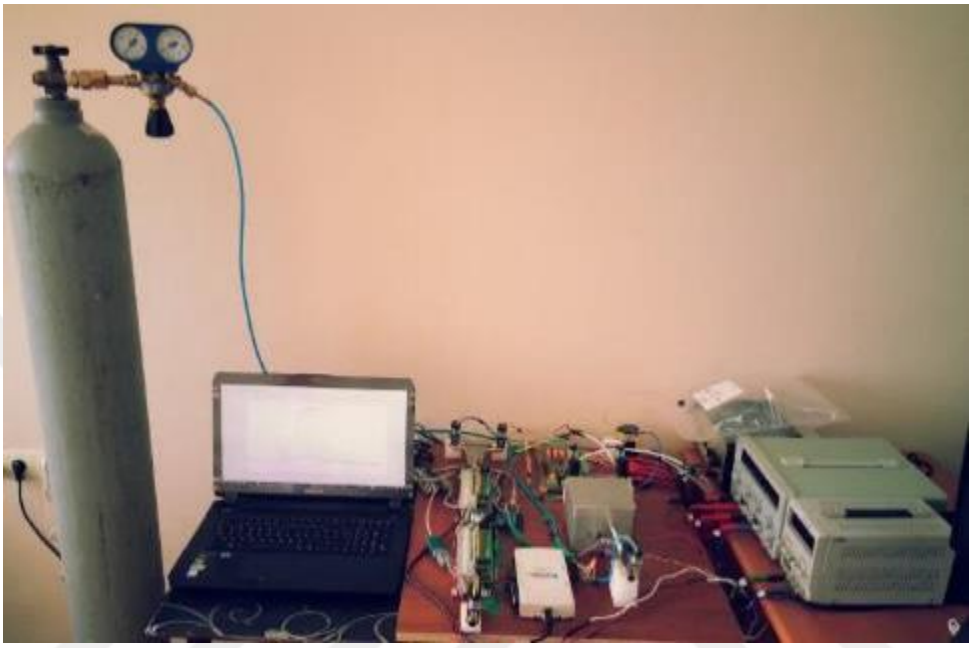
Çalışmada kullanılan MOY sensör çeşitleri ve KKM sensörlerine ait görsel Şekil 36' da verilmektedir.



Şekil 36. Çalışmada kullanılan MOY ve KKM sensör çeşitleri

2.1.10. Gerçekleştirilen E-burun Devresinin Çalışması

Yukarıda verilen devre elemanlarının kullanılması sonucunda oluşturulan e-burun devresine ilişkin görsel Şekil 37'de verilmektedir.



Şekil 37. Gerçekleştirilen e-burun devresi

Geliştirilen elektronik burun devresiyle yapılan deneyler dört aşamadan oluşmaktadır. İlk aşamada tüm sistem 100 saniye boyunca kuru hava ile temizlenir ve bu sürenin ardından valfler kapatılır. İlk temizlemenin ardından vakum pompasıyla Tedlar torbadaki nefes örneği 40 saniye boyunca KKM ve MOY sensör haznelerine aktarılır. 40 saniyenin ardından tüm valfler kapatılır ve 30 saniye boyunca sensör haznelerinde hapsedilen nefes örneklerine sensörlerin tepki vermesi sağlanır. Son olarak ise 140 saniye boyunca sistem tekrar kuru hava ile temizlenerek sistem bir sonraki deneye hazır hale getirilir. Gerçekleştirilen bir deney süresince devrede bulunan valflerin konumları Tablo 8' de verilmektedir.

Sistemde kullanılan kuru hava tüpünün ayarlı vanası yardımıyla kuru hava akış hızı 10 litre/min olarak sabitlenmiştir. Bu şekilde deneyler öncesinde ve deneyler sonrasında tüm sistem aynı akış hızı ile ve iyi bir şekilde temizlenebilmektedir. Sistemde kullanılan vakum pompasına uygulanan sabit besleme gerilimi sayesinde nefes örnekleri tüm deneyler boyunca sensör haznelerine aynı hızlarda aktarılmıştır. Vakum pompasının besleme gerilimi elektronik burun sisteminin kurulumu aşamasında belirlenmiştir.

Tablo 8. Bir deney süresince valflerin durumları

Yapılan İşlemler ve Süreleri	Valfler ve Durumları (Açık-Kapalı)					
	V1	V2	V3	V4	V5	V6
Deney Öncesi Ön Temizleme	Açık	Kapalı	Kapalı	Açık	Açık	Açık
Nefes Örneklerinin Sensörlere Gönderilmesi (40sn)	Kapalı	Açık	Açık	Kapalı	Kapalı	Kapalı
Nefes Örneklerinin Sensör Haznelerinde Hapsedilmesi (30sn)	Kapalı	Kapalı	Kapalı	Kapalı	Kapalı	Kapalı
Sistemin Son Temizlenmesi (140sn)	Açık	Kapalı	Kapalı	Açık	Açık	Açık

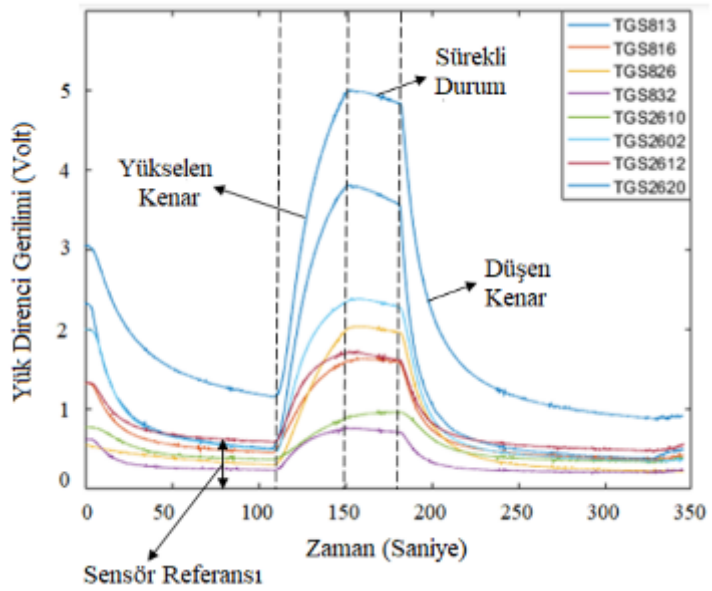
Bu aşamada sensör haznelerinin ve tedlar torbaların hacimleri göz önünde bulundurularak nefes örnekleri 3,6 litre/min akış hızı ile sensörlere ulaştırılmıştır. Gerçekleştirilen bir deney sonucunda elde edilen MOY ve KKM sensör tepkileri Şekil 38' de verilmektedir.

2.2. Nefes Örneklerinin Toplanması

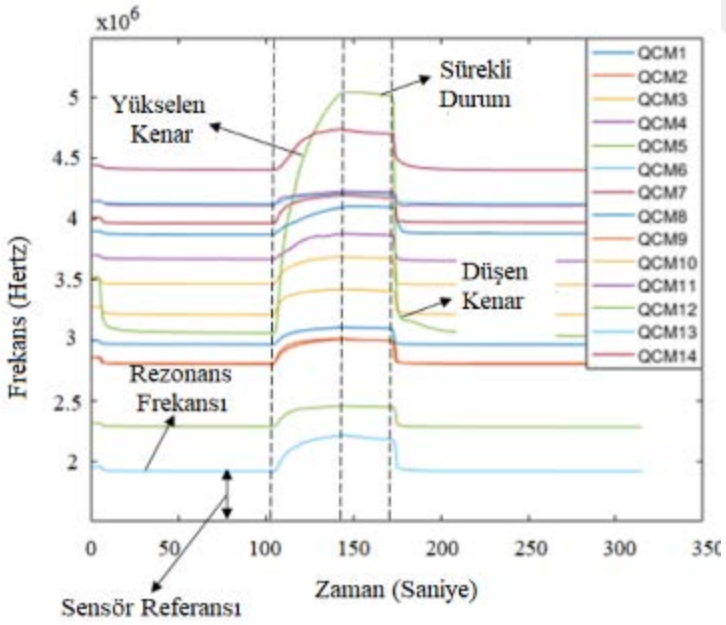
Bu çalışma kapsamında 40 sağlıklı gönüllüden ve Karadeniz Teknik Üniversitesi Tıp Fakültesi Farabi Hastanesi'nde tedavi gören 60 akciğer kanseri hastası gönüllüden alınan nefes örnekleriyle toplamda 338 deney gerçekleştirilmiştir. Gerekli tüm etik kurul belgeleri çalışma öncesi Karadeniz Teknik Üniversitesi'nden alınmış olup, etik onay numarası 24237859-517'dir. Çalışmaya katılan hasta gönüllülerin her birinin akciğer kanseri tanısı bronskopi ve biyopsi sonuçlarına göre kesinleştirildikten sonra hastalardan nefes örnekleri alınmıştır.

Çalışmaya katılan akciğer kanseri hastalarının tümörlerinin evreleri Amerikan Ortak Kanser Komitesi (American. Joint Committee on Cancer-AJCC) tarafından belirlenmiş Tümör Genişliği (T), Bölgesel Lenf Düğümü Metastazların genişliği (N) ve Uzak Matetastazı (M) değerlendiren TNM yönteminin 7. sürümüyle belirlenmiştir. Çalışmaya katılan kanser hastası gönüllülerden nefes örnekleri toplanmadan önce hastalar herhangi bir cerrahi operasyon geçirmemişlerdir. Nefes örneği veremeyecek durumda olan hastalar çalışma dışında tutulmuştur. Her akciğer kanseri gönüllüden alınan nefes örneğiyle en az fazla kez deney yapılmıştır. Çalışmaya katılan sağlıklı gönüllülerin herhangi bir hamilelik durumu ve farklı bir akciğer hastalığı bulunmamaktadır. Sağlıklı gönüllülerin yarısı sigara kullanan bireylerden oluşmaktadır. Nefes örneklerinin toplanması hem hasta hem de sağlıklı

bireyler için tamamen gönüllülük esasına dayanmaktadır. Nefes örneklerinin toplandığı hasta ve sağlıklı gönüllülere ait bilgiler Tablo 9'da verilmektedir.



(a)



(b)

Şekil 38. Bir deney sonucu oluşan (a) MOY sensör, (b) KKM sensör işaretleri

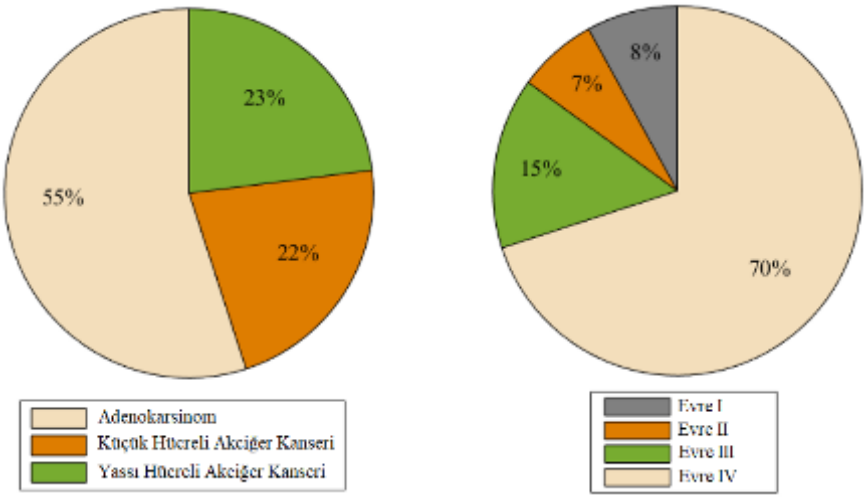
Deneylere katılan bireylerin nefesleri Tedlar torbalar kullanılarak toplanmıştır. Her bir gönüllüye ait tedlar torba sadece tek sefer kullanılmıştır. Tedlar torbalar içerden ve dışardan

gaz kaçaklarına izin vermediğinden dolayı bireylerden alınan nefes örneklerinin içeriğinde herhangi bir değişiklik olmadan deneyler gerçekleştirilebilmektedir. Deneylere katılan gönüllüler gece boyunca herhangi bir yiyecek yememiş ve nefes örneklerini aç olarak vermişlerdir. Sigara kullanan gönüllüler de 2 saat öncesinden sigara içmeyi bırakmışlardır.

Tablo 9. Çalışmaya katılan gönüllülere ilişkin bilgiler

	Akciğer Kanseri Hastaları (60 kişi)	**Sağlıklı Gönüllüler (40 kişi)**
Yaş (Ortalama / Standart Sapma)	60.7 / 8	48.2 / 9
Cinsiyet (Kadın / Erkek)	13/47	10/30
Sigara Kullanan / Sigara Kullanmayan	0/60	20/20
Sigara Kullanıp Bırakmış Olan	45/60	0/40

Gönüllü bireylerden nefes örnekleri toplanırken Tedlar torbaların kapak kısmında bulunan hava çıkışı, gönüllüler nefes vermeye başladığında açık bırakılmış ve nefeslerinin son bölümünde kapatılmıştır. Bu sayede çalışmaya katılan gönüllülerin özellikle solunum sisteminin üst kısmında bulunan nefes örneğinden ziyade akciğerlerde bulunan nefes örneklerinin toplanması sağlanmıştır. Çalışmaya katılan akciğer kanseri hastalarının hangi akciğer kanser hücre türüne ve kanser evresine sahip olduğu Şekil 39' da dairesel grafiklerde verilmiştir.



(a) (b)

Şekil 39. (a) Hasta gönüllülerin sahip olduğu kanser hücre türüne göre dağılım, (b) Hasta gönüllülerin kanser evresine göre dağılımı

Şekil 39’ da görülebileceği gibi çalışmaya katılan 60 akciğer kanseri hastası gönüllüden 33 gönüllü Adenakarsinom, 14 gönüllü Yassı Hücreli Karsinom ve 13 gönüllü Küçük Hücreli Akciğer Kanseri çeşidine sahiptir. 42 akciğer kanseri hastası gönüllü hastalığın IV. evresinde bulunmakta iken, 9 gönüllü III. evre, 5 gönüllü I. Evre ve 4 gönüllü de hastalığın II. Evresindedir.

2.3. Veri Analizi ve Öznitelik Çıkarma

Gerçekleştirilen deneyler sonucu elde edilen verilerden öznitelikler çıkarılmadan önce veriler üzerinde bazı ön işlemler uygulanmıştır. Elde edilen verileri doğru bir şekilde görselleştirmek ve bu verilerden kullanışlı bilgiler elde etmek için hem MOY hem de KKM sensörlerden alınan verilere sırasıyla (41) ve (42) denklemleri kullanılarak referans düzeltme işlemi uygulanmıştır.

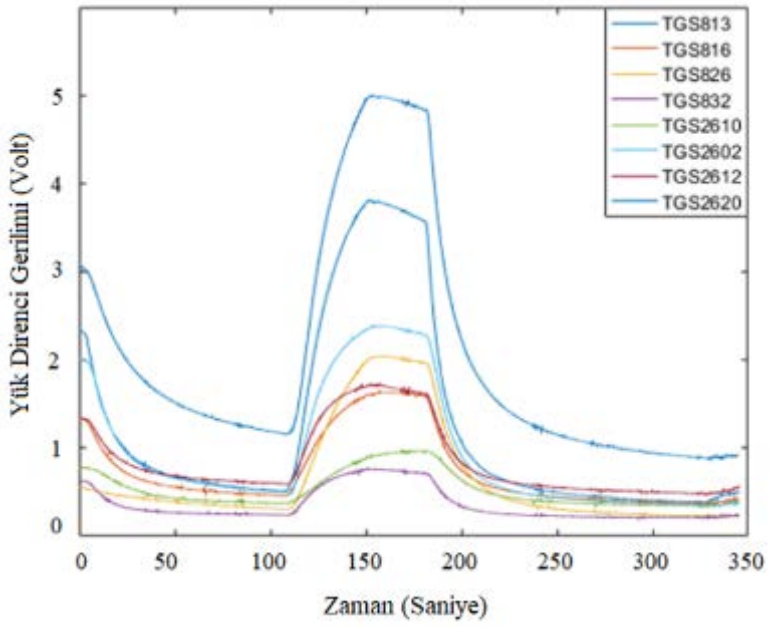
$$v_{n,s,r}(t) = v_{n,s}(t) - v_{n,s}(0) \tag{41}$$

$$f_{n,s,r}(t) = f_{n,s}(t) - f_{n,s}(0) \tag{42}$$

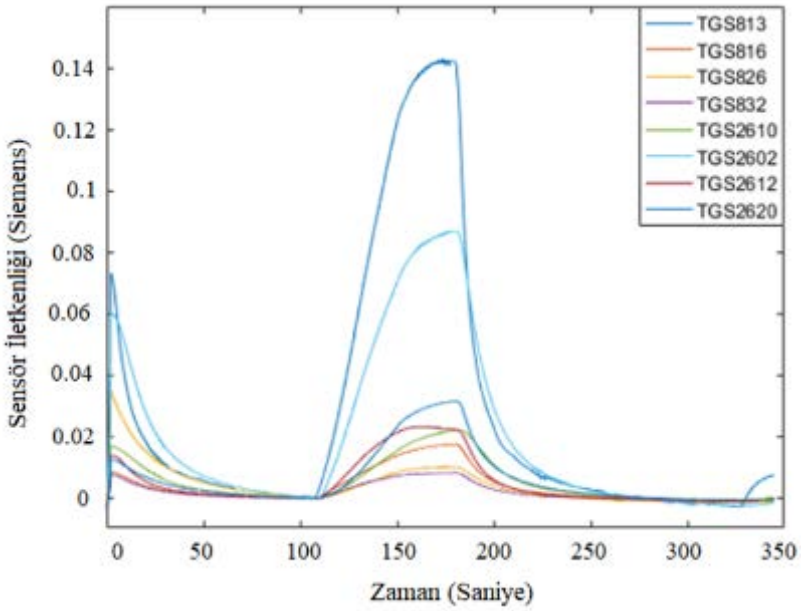
Bu denklemlerde $v_{n,s}(t)$ ham sensör verilerini, $v_{n,s}(0)$ sensörlere nefes örneği iletildiği ilk anda elde edilen sensör verilerini ve $v_{n,s,r}(t)$ referansı düzeltilmiş sensör verilerini göstermekteyken, $f_{n,s}(t)$ ham frekans verilerini, $f_{n,s}(0)$ sensörlere ait rezonans frekans değerini ve $f_{n,s,r}(t)$ referansı düzeltilmiş sensör verilerini temsil etmektedir. Literatürde bulunan elektronik burun çalışmaları incelendiğinde, MOY sensörlere seri bağlı yük direncinden elde edilen gerilim bilgisinden ziyade, MOY sensöre ait iletkenlik bilgisinin kullanıldığı belirlenmiştir. Bu çalışmada sensörlere bağlı yük dirençleri üzerinden elde edilen gerilim verileri (43) denklemi kullanılarak iletkenlik verisine dönüştürülmüştür.

$$G_{n,s}^{R}(t) = \frac{V_{n,s}^{R}(t)}{(V_c - V_{n,s}^{R}(t))R_{L,s}} \tag{43}$$

Bu denklemde V_c sensörlerin besleme gerilimini, $R_{L,s}$ MOY sensörlere seri bağlı direnç değerlerini ve $G_{n,s}^{R}(t)$ sensörlere ait iletkenlik verisini göstermektedir. Şekil 40Şekil 40’ ta verilen grafik MOY sensörlerden elde edilen ham verileri ve aynı referans noktasına çekilmiş iletkenlik verilerini göstermektedir.



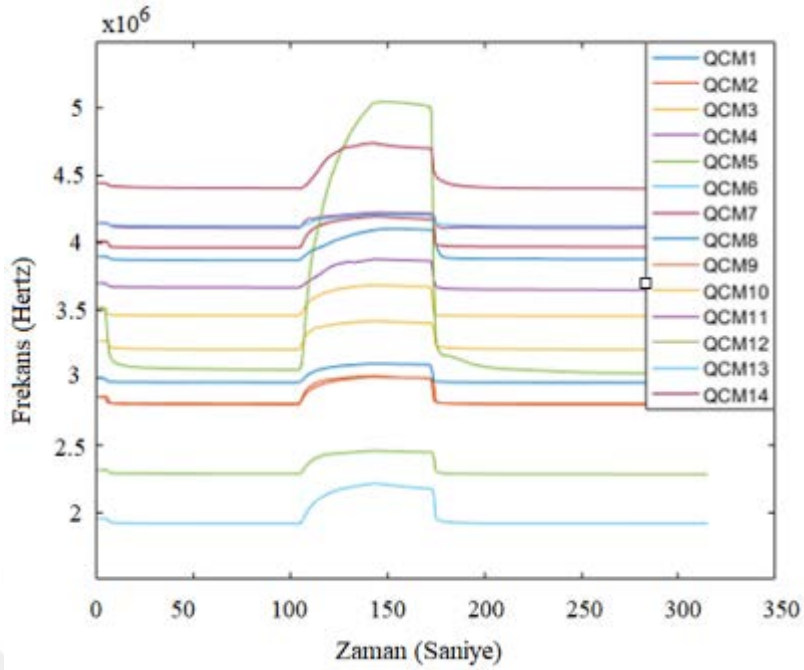
(a)



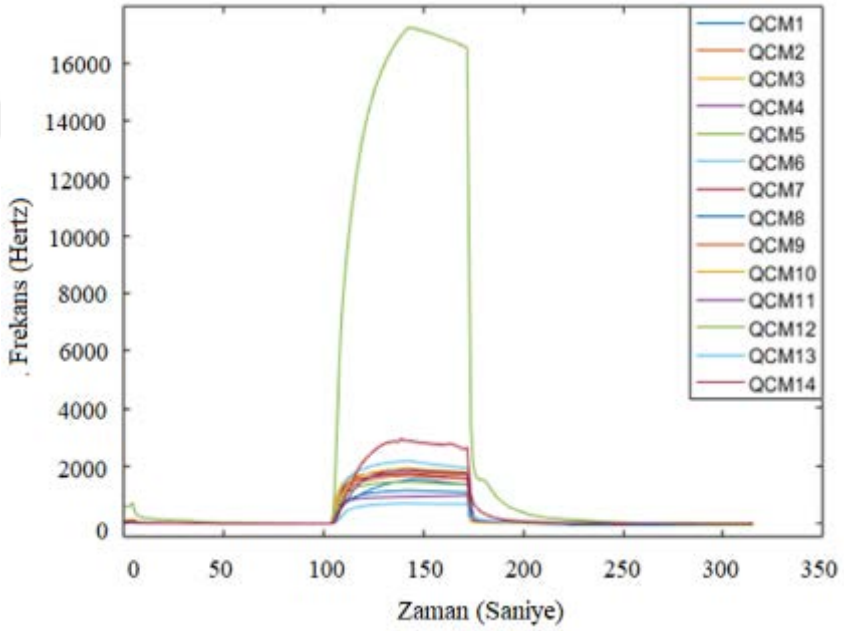
(b)

Şekil 40. MOY sensörler için: a) İşlenmemiş Sensör verileri, b) Referans düzeltme ve iletkenlik dönüşümü yapılmış veriler

Şekil 41'de verilen grafikte KKM sensörlerden elde edilen ham verileri ve aynı referansa çekilmiş frekans verilerini göstermektedir.



(a)

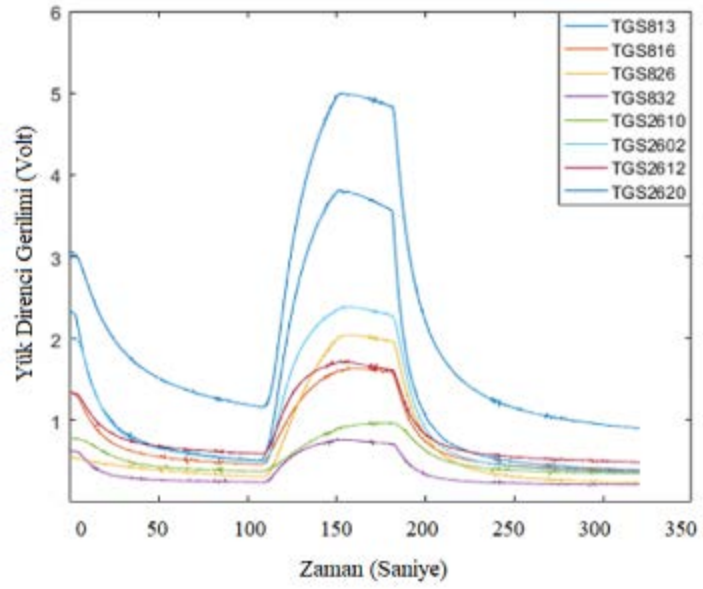


(b)

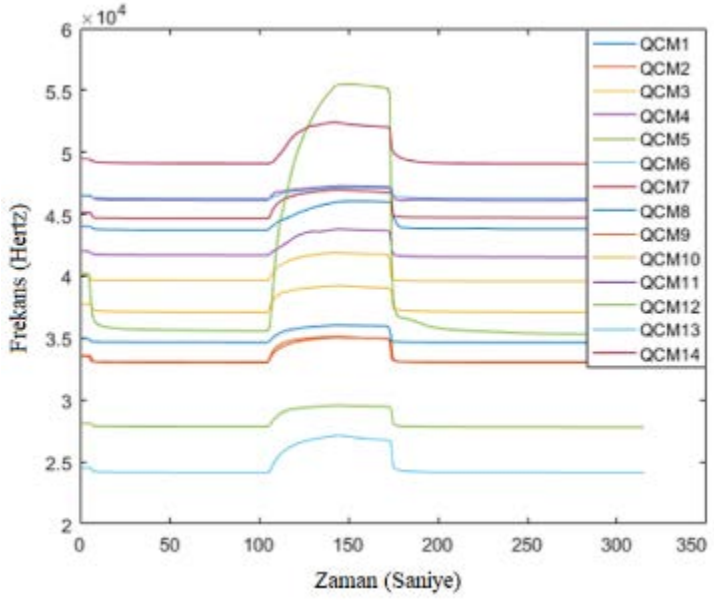
Şekil 41. KKM sensörler için: a) İşlenmemiş Sensör verileri, b) Referans düzeltilmiş sensör verileri

Doktora çalışmamız süresince toplam 338 adet nefes örneği deneyi gerçekleştirildi. Bu deneylerden 219 adet deney hasta gönüllülerden alınan nefes örnekleriyle gerçekleştirilirken, 119 deney ise sağlıklı gönüllülerden alınan nefes örnekleriyle

gerçekleştirildi. Sağlıklı gönüllülere ait toplam 119 deney içerisinde 64 adet deney sigara kullanmayan sağlıklı bireylerden elde edilen nefes örnekleriyle 55 adet deney ise sigara kullanan sağlıklı bireylerden alınan nefes örnekleriyle gerçekleştirilmiştir. Hasta, sigara kullanan sağlıklı ve sigara kullanmayan sağlıklı gönüllülerden alınan nefes örnekleriyle yapılan deneylerden elde edilen MOY ve KKM sensörlere ait verilere ilişkin birer görsel sırasıyla Şekil 42,Şekil 42 Şekil 43 ve Şekil 44' te verilmektedir.

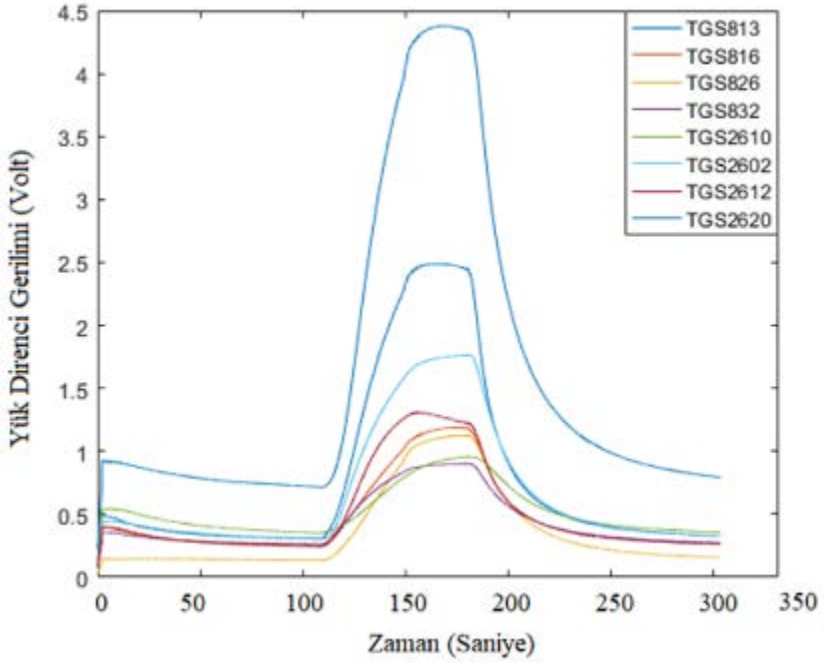


(a)

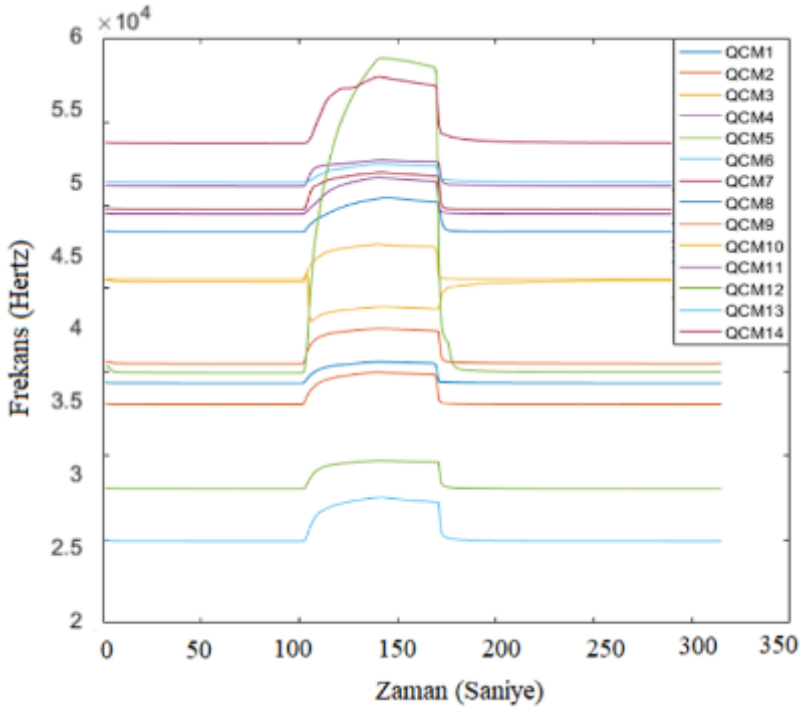


(b)

Şekil 42. Akciğer kanseri hasta gönüllüye ait (a) MOY, (b) KKM sensör işaretleri

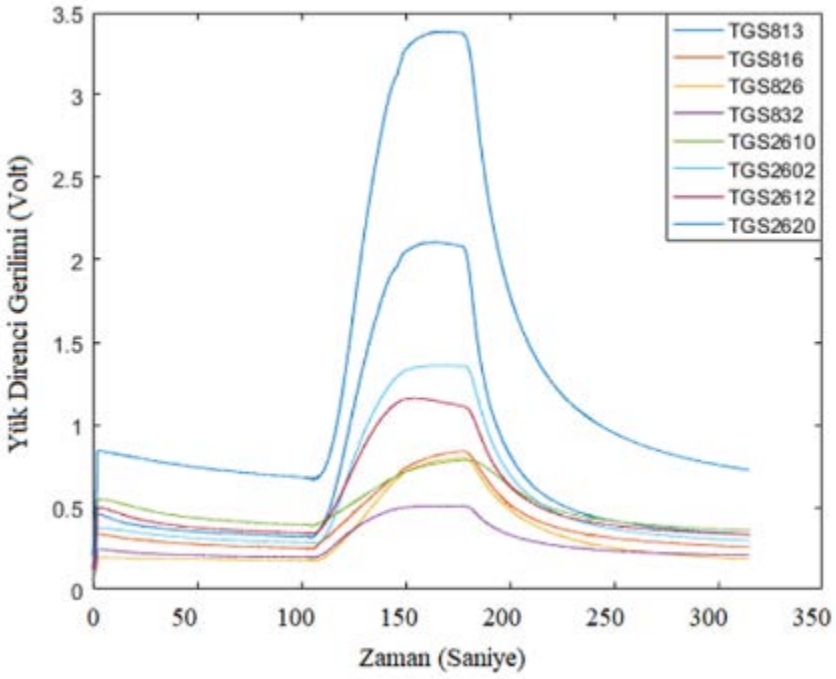


(a)

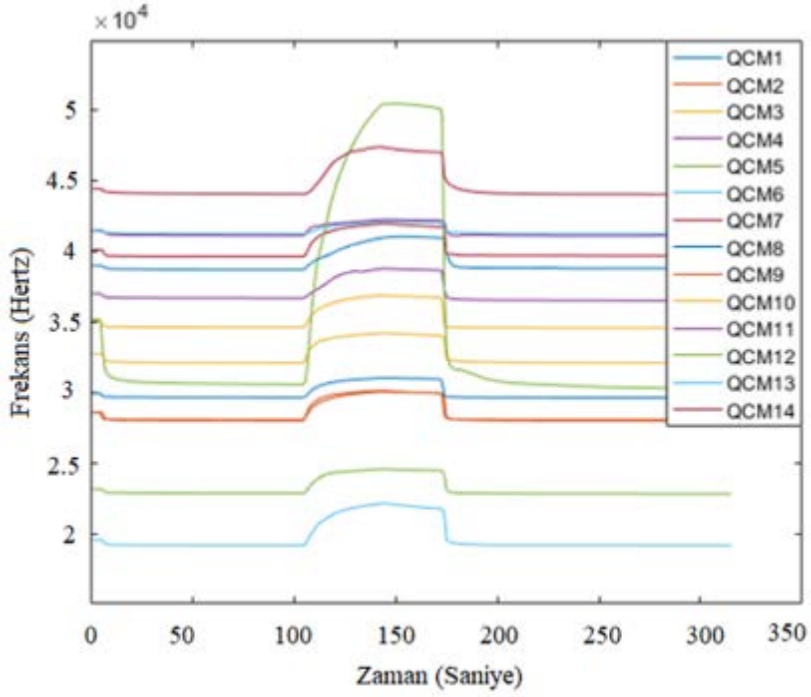


(b)

Şekil 43. Sigara kullanan sağlıklı gönüllüye gönüllüye ait (a) MOY, (b) KKM sensör işaretleri



(a)



(b)

Şekil 44. Sigara kullanmayan sağlıklı gönüllüye ait deney sonucu

Öznitelik çıkarma işlemi, deneyler sonucu elde edilen sensör cevaplarından sınıflandırma öncesinde anlamlı bilgiler çıkarmayı sağlar. Sınıflandırma başarısını artırmak için en uygun özniteliklerin seçilmesi gerekmektedir. En iyi özniteliklerin seçilmesi ise

üzerinde çalışılan problemin doğasına göre değişmektedir. Bu nedenle belirlenecek olan öznitelikler çeşitleri hakkında kesin bir kural bulunmamaktadır. Bu çalışmada kullanılacak olan öznitelikler seçilmeden önce MOY ve KKM sensör cevapları ayrıntılı şekilde incelenmiş ve aşağıdaki özniteliklerin kullanılmasına karar verilmiştir.

MOY sensör verileri için;

- 100 saniye-210 saniyeler arasında elde edilen verilerin maksimum değeri
- 100 saniye-210 saniyeler arasında elde edilen verilerin ortalama değeri
- 100 saniye-210 saniyeler arasında elde edilen verilerin varyans değeri
- 100 saniye-210 saniyeler arasında elde edilen verilerin basıklık (Kurtosis) değeri
- 100 saniye-210 saniyeler arasında elde edilen verilerin eğrilik (Skewness) değeri
- 100 saniye-170 saniyeler arasında TGS826-TGS832 sensör verileri arasında kalan alan
- 100 saniye-170 saniyeler arasında TGS813-TGS2620 sensör verileri arasında kalan alan
- 100 saniye-110 saniyeler arasında TGS813 sensör verisinin eğimi
- 100 saniye-120 saniyeler arasında TGS813 sensör verisinin eğimi
- 100 saniye-130 saniyeler arasında TGS813 sensör verisinin eğimi
- 100 saniye-110 saniyeler arasında TGS2602 sensör verisinin eğimi
- 100 saniye-120 saniyeler arasında TGS2602 sensör verisinin eğimi
- 100 saniye-130 saniyeler arasında TGS2602 sensör verisinin eğimi
- 140 saniye-170 saniyeler arasında TGS2620 sensör verisinin eğimi
- 140 saniye-160 saniyeler arasında TGS2620 sensör verisinin eğimi
- 140 saniye-150 saniyeler arasında TGS2620 sensör verisinin eğimi
- 100 saniye-140 saniyeler arasında elde edilen verilerin eğrilik değeri
- 100 saniye-140 saniyeler arasında elde edilen verilerin basıklık değeri
- 140 saniye-170 saniyeler arasında tüm sensör verilerine ait, ortalama, varyans, eğrilik ve basıklık değerleri kullanılmıştır.

KKM sensör verileri için ise;

- KKM6 ve KKM14 sensör verileri arasında kalan alan
- KKM2 ve KKM11 sensör verileri arasında kalan alan
- KKM9 ve KKM11 sensör verileri arasında kalan alan
- KKM14 ve KKM7 sensör verileri arasında kalan alan
- 100 saniye-140 saniyeler arasında KKM11 sensör verisinin eğimi
- 100 saniye-140 saniyeler arasında KKM6 sensör verisinin eğimi

- KKM5 sensörünün maksimum değeri kullanılmıştır.

Kullanılan öznitelikler arasından ortalama değer hesabı (44) denklemi kullanılarak gerçekleştirilmektedir.

$$\overline{X} = \frac{1}{N}\sum_{i=1}^{N} X_i \tag{44}$$

(44) denkleminde X, ortalaması hesaplanacak veriyi göstermekteyken, N ve $\overline{X}$ sırasıyla örnek sayısını ve ortalama değeri göstermektedir. Varyans hesabı ise (45) denklemi kullanılarak belirlenmektedir.

$$s^2 = \frac{\sum_{i=1}^{N}(X_i-\bar{X})^2}{N-1} \tag{45}$$

Kullanılan özniteliklerden biri olan basıklık (Kurtosis) ifadesi ise literatürde reel değerli değişkenlerin olasılık dağılım grafiğinin ne kadar basık veya sivri olduğunu belirlemeye yarayan bir ölçümü ifade etmektedir. N değişkenden oluşan bir veri için basıklık değeri (46) denklemiyle hesaplanabilir.

$$\text{Basıklık} = \frac{1}{N}\frac{\sum_{i=1}^{N}(X_i-\bar{X})^4}{\sigma^4} \tag{46}$$

(46) denkleminde σ ifadesi veri setine ait standart sapmayı göstermektedir. Kullanılan bir diğer öznitelik çarpıklık ise literatürde bir dağılımın simetrik olup olmama durumunu incelemek için kullanılır. Çarpıklık ifadesi üçüncü standardize edilmiş momenttir ve (47) denklemiyle belirlenir.

$$\text{Çarpıklık} = \frac{1}{(N-1)}\frac{\sum_{i=1}^{N}(X_i-\bar{X})^3}{\sigma^3} \tag{47}$$

Öznitelik matrisinde bulunan iki sensör arasındaki alan için sensör işaretlerinin integralinin alınması gerekmektedir. Bir sensör işaretini f(x) ile adlandırıldığı varsayılırsa, [a-b] noktaları arasında kalan sensör cevabının integrali (48) denklemiyle hesaplanabilir.

$$\text{Integral} = \sum_{i=1}^{N} \mathrm{f}(X_i)\Delta X_i \tag{48}$$

(48) denkleminde ΔX_i=(b-a)/n şeklinde ifade edilir ve bu ifade [a-b] aralığını n adet parçaya bölünmesi sonucu elde edilen tek bir parçaya karşılık gelmektedir.

3. BULGULAR VE TARTIŞMA

Yapılan deneyler sonucunda elde edilen veriler hem iki sınıflı (akciğer kanseri-sağlıklı) hem de üç sınıflı (akciğer kanseri- sigara kullanan sağlıklı- sigara kullanmayan sağlıklı) verileri içerecek şekilde sınıflandırılmıştır. Yukarıda verilen özniteliklerin kullanılması sonucu MOY sensörlere ait verilerin kullanılmasıyla oluşturulan öznitelik matrisi (338x91), KKM sensör verileriyle oluşturulan öznitelik matrisi (338x7) boyutunda olmaktadır. Çalışmada elde edilen öznitelik matrisleri hem öznitelik matrisi boyutu azaltmadan hem de bu matrisin boyutu TBA ve DDA algoritmalarıyla azaltılarak sınıflandırılmıştır. Her iki boyut azaltma algoritması kullanılırken boyutu azaltılmış olan verinin, orijinal verinin içerdiği bilginin en az 90%'ını içermesine dikkat edilmiştir. MOY sensör verilerinden elde edilen öznitelik matrisinin (338x91) olan boyutu TBA ve DAA algoritmaları kullanılarak (338x14) boyutuna indirgenmiştir. KKM sensör verilerinden elde edilen öznitelik matrisinin (338x7) olan boyutu TBA ve DAA algoritmaları kullanılarak sırasıyla (338x4) ve (338x6) boyutlarına indirgenmiştir. MOY ve KKM sensör verilerinden elde edilen öznitelik matrislerinin birleştirilmesiyle oluşturulan (338x98) boyutlu öznitelik matrisinin boyutu TBA ve DAA algoritmalarının kullanılmasıyla (338x19) boyutuna indirgenmiştir.

Gerçekleştirilen sayısal veri işleme ve boyut indirgeme işlemlerinden sonra elde edilen öznitelik matrislerinin her biri KA, k-EYK, DVM ve RO algoritmalarıyla sınıflandırılmıştır. DVM yöntemiyle sınıflandırma yapılırken 3 farklı çekirdek fonksiyonu kullanılmıştır. Bu çekirdek fonksiyonları; lineer fonksiyon, karesel (quadratic) fonksiyon ve kübik fonksiyondur. Bu çalışmada çekirdek fonksiyonların kısaltılmış şekilleri; Lineer DVM için L-DVM, karesel DVM için Q-DVM ve kübik DVM için K-DVM şeklinde gösterilmektedir Çalışmada kullanılan sınıflandırma algoritmalarının performanslarının belirlenmesi için 5-kat çapraz doğrulama yöntemi kullanılmıştır. Her bir öznitelik matrisi için her bir sınıflandırma algoritmasıyla sınıflandırma işlemi 10 kez tekrarlanmıştır ve her bir sınıflandırıcıya ait sonuçlar; ortalama başarı, en yüksek başarı, en düşük başarı ve standart sapma değeri verilecek şekilde Tablo 10 da verilmektedir. Belirtilen öznitelik matrisleri, hangi sensör verilerine ait özniteliklerin kullanıldığı ve bu öznitelik matrislerinin hangi boyut azaltma algoritmasıyla boyutlarının azaltıldığına göre kısaltma yapılarak verilmiştir. Örneğin MOY sensör verilerinden elde edilerek ve boyutu azaltılmamış olan öznitelik matrisi "MOY" şeklinde, boyutu TBA yöntemiyle azaltılarak elde edilen öznitelik

matrisi TBA(MOY) ve boyutu DAA yöntemiyle azaltılarak elde edilen öznitelik matrisi ise DAA(MOY) şeklinde verilmiştir.

k-EYK algoritmasıyla gerçekleştirilen sınıflandırma işleminde komşu sayısı k değerinin yapılan denemeler sonucunda k=3, uzaklık ölçüm yönteminin ise öklid uzaklık ölçüm fonksiyonu kullanılmasına karar verilmiştir. DVM ile yapılan sınıflandırmada farklı çekirdek fonksiyonları kullanılarak bu fonksiyonların sınıflandırıcı performansına etkileri incelenmiştir. Kullanılan çekirdek fonksiyonlarının sınıflandırma sonucuna etkisi yine Tablo 4' te açık şekilde görülebilmektedir. İki sınıflı veri sınıflandırma işleminde son olarak kullanılan sınıflandırma algoritması RO algoritmasıdır. RO algoritmasının sınıflandırma işleminde performansını etkileyen en önemli parametreler N (geliştirilecek ağaç sayısı) ve m (en iyi bölünmeyi belirlemek için her bir düğümde kullanılan değişkenlerin sayısı) değişkenleridir. Bu çalışmada en iyi sonuçların elde edildiği değişkenler, N=30 ve m= 100 olarak belirlenmiştir. Veri sınıflandırma işlemlerinde sınıflandırma başarısı belirlenirken sadece doğruluk oranının kullanılması sınıflandırma başarısı hakkında yeteri kadar anlamlı bilgi vermemektedir. Bu nedenle doğruluk bilgisinin yanında duyarlılık, belirlilik, pozitif tahmin değeri ve negatif tahmin değeri sonuçlarının da verilmesi sınıflandırma sonuçlarının daha doğru şekilde yorumlanabilmesini sağlayacaktır. Doğruluk oranı, duyarlılık, belirlilik, pozitif tahmin değeri ve negatif tahmin değeri ifadeleri sırasıyla (49), (50), (51), (52), (53) denklemleriyle hesaplanmaktadır.

$$\text{Doğruluk oranı} = (\%)\frac{DP+DN}{DP+YP+DN+YN}x100 \tag{49}$$

$$\text{Duyarlılık} = (\%)\frac{DP}{DP+YN}x100 \tag{50}$$

$$\text{Özgüllük} = (\%)\frac{DN}{DN+YP}x100 \tag{51}$$

$$\text{Pozitif tahmin değeri} = (\%)\frac{DP}{DP+YP}x100 \tag{52}$$

$$\text{Negatif tahmin değeri} = (\%)\frac{DN}{DN+YN}x100 \tag{53}$$

Tablo 10. Kullanılan özellikler ve sınıflandırma algoritmaları için sınıflandırma sonuçları.

		Sınıflandırma Algoritmaları					
Kullanılan Öznitelik Matrisleri		KA	L-DVM	Q-DVM	K-DVM	k-EYK	RO
	MOY	80,26 82,4-77,5 1,66	82,82 84,6-81,1 1,25	83,76 84,6-83,1 0,65	82,82 87,3-79,6 2,66	80,30 83,1-78,1 1,98	**86,34** **87,6-85,2** **1,17**
	TBA (MOY)	91,98 92,6-91,4 0,49	64,62 66,8-63,9 0,84	75,46 76,6-72,5 1,67	90,20 90,8-89,6 0,47	91,52 92,6-91,1 0,62	**92,6** **93,8-91,1** **1,18**
	DAA (MOY)	89,02 91,1-87,9 1,23	91,82 92,3-90,5 0,75	90,86 91,7-89,6 0,91	87,24 88,2-85,8 1,22	88,2 89,1-87,3 0,76	**92,12** **93,2-91,4** **0,69**
	KKM	70,88 71,9-68,9 1,36	64,14 65,4-63 0,95	74,84 76,9-72,2 1,75	72,5 74,5-70,4 1,55	74,88 77,2-72,8 1,59	**75,48** **78,4-74,3** **1,78**
	TBA (KKM)	80,78 82,2-79,00 1,32	64,8 64,8-64,8 0	86,52 88,5-83,4 2,14	83,06 84,6-81,7 1,19	88,30 89,3-87,3 0,83	**86,64** **88,5-84,6** **2,02**
	DA (KKM)	69,44 71,6-68,3 1,29	71,90 73,7-70,4 1,29	74,44 75,1-73,4 0,82	71,60 74,6-68,6 2,40	77,32 79,9-75,1 1,82	**74,96** **76,1-73,7** **0,93**
	MOY+ KKM	78,52 80,8-76,00 2,17	81,14 82,5-79,9 1,01	**88,54** **89,9-87,9** **0,84**	88,28 89,9-86,7 1,41	81,62 82,5-81,1 0,53	86,52 87,9-85,2 1,09
	TBA(MOY+KKM)	90,76 92,3-89,1 1,26	64,60 65-64 0,54	64,60 65-64 0,54	86,40 88,2-84,9 1,25	90,5 91,1-89,6 0,63	**92,30** **92,9-91,4** **0,60**
	DAA(MOY+KKM)	93,26 93,8-92,6 0,53	**95,36** **96,2-94,7** **0,57**	95,00 95,3-94,7 0,30	93,08 93,8-92,6 0,54	90,04 90,8-88,8 0,77	95,30 96,2-93,8 1,01
	TBA (MOY)+TBA(KKM)	91,46 92,6-90,2 1,58	64,60 65-64 0,54	83,18 84,9-82 1,06	89,3 91,1-87 1,69	93,26 94,1-92,6 0,53	**93,74** **94,4-92,9** **0,57**
	DAA(MOY)+ DAA(KKM)	91,22 91,7-90,8 0,34	2,7 93,2-92,3 0,45	92,6 93,5-91,1 0,90	90,62 91,7-89,6 0,75	89,25 87,6-91,4 1,43	**93,68** **95,9-92,6** **1,31**

(49)-(53) arası denklemler kullanılarak elde edilen sınıflandırma detaylarına ilişkin veriler Tablo 11' de görülebilir.

Tablo 11. İki sınıflı sınıflandırma sonuçlarına ilişkin sınıflandırma detayları

	Duyarlılık (%)	Özgüllük (%)	PTD (%)	NTD (%)	Doğruluk (%)
MOY-RO	92.28	75.74	87.39	83.33	86.34
TBA(MOY) -RO	95.21	88.60	92.11	90.59	92.62
DAA(MOY) -RO	93.41	89.73	94.01	87.60	92.12
KKM-RO	87.16	55.80	78.18	69.47	75.48
TBA(KKM) -RO	94.27	72.57	86.19	86.86	86.64
DA(KKM) -RO	80.83	67.57	81.94	65.55	74.96
(MOY+KKM) -QDVM	91.83	82.37	90.54	84.34	88.54
TBA(MOY+KKM) -RO	95.83	85.79	92.47	91.07	92.30
DAA(MOY+KKM) -RO	95.82	93.90	96.31	91.73	95.36
TBA(MOY)+ TBA(KKM) -RO	95.92	89.18	94.17	92.17	93.74
DAA(MOY)+ DAA(KKM) -RO	95.07	91.19	94.93	90.75	93.68

3.1.1. Üç Sınıflı Veri sınıflandırma

Tez çalışması boyunca gerçekleştirilen diğer bir sınıflandırma işlemi de üç sınıflı veri sınıflandırma işlemidir. Bu sınıflandırma işleminde akciğer kanseri, sigara kullanmayan sağlıklı gönüllü ve sigara kullanmayan sağlıklı gönüllüler ait veriler üç sınıf içerecek şekilde sınıflandırılmıştır. İki sınıflı sınıflandırma yönteminde olduğu gibi hem boyut azaltımı yapılmadan hem de TBA ve DDA yöntemlerinin kullanılmasıyla boyutu azaltılan öznitelik matrisi KA, k-EYK, DVM ve RO algoritmaları kullanılarak sınıflandırılmıştır. Yapılan sınıflandırma işlemine ait sonuçlar Tablo 12’ de verilmektedir. İki sınıflı sınıflandırma işleminde olduğu gibi belirtilen öznitelik matrisleri, hangi sensör verilerine ait özniteliklerin kullanıldığı ve bu öznitelik matrislerinin hangi boyut azaltma algoritmasıyla boyutlarının azaltıldığına göre kısaltma yapılarak verilmiştir. Örneğin MOY sensör verilerinden elde edilerek ve boyutu azaltılmamış olan öznitelik matrisi “MOY” şeklinde, boyutu TBA

yöntemiyle azaltılarak elde edilen öznitelik matrisi TBA(MOY) ve boyutu DAA yöntemiyle azaltılarak elde edilen öznitelik matrisi ise DAA(MOY) şeklinde verilmiştir.

Tablo 12. Kullanılan özellikler ve sınıflandırma algoritmaları için sınıflandırma sonuçları

		Sınıflandırma Algoritmaları					
Kullanılan Öznitelik Matrisleri		KA	L-DVM	Q-DVM	K-DVM	k-EYK	RO
	MOY	75,34 77,8-72,8 1,90	75,52 77-74,6 1,08	81,12 82,1-79,3 1,17	81,28 82-79,3 1,12	74,3 79,9-71,3 3,30	**81,54** **82,8-79,9** **1,09**
	TBA(MOY)	85,20 86,1-84,3 0,67	67,86 70,2-64,9 2,17	67.66 70,2-64,9 2,11	85.76 86,4-84,9 0,62	81,06 81,9-79,6 0,90	**87,16** **88,1-86,1** **0,88**
	DAA(MOY)	88,80 90,1-87,3 1,11	**93.20** **93,1-91,3** **0,78**	92,60 92,9-91,7 0,45	91,56 92,8-90,2 1,06	90,10 90,8-89,4 0,51	90,04 90,8-89,1 0,80
	KKM	66,82 70,7-64,2 2,70	64,32 64,8-64 0,43	71,96 74,0-70,1 1,46	69,66 73,4-66,5 2,51	70,50 72,2-68,9 1,33	**73,18** **75,1-70,7** **1,77**
	TBA(KKM)	74.96 76,9-73,7 1,25	67,86 70,2-64,9 2,17	67.66 70,2-64,9 2,11	82,22 84,3-79,3 1,93	**85.96** **87-84,9** **0,89**	80,20 81,0-79 0,87
	DAA(KKM)	67,30 68,6-65,7 1,30	67,86 70,2-64,9 2,17	67.66 70,2-64,9 2,11	68,92 70,1-68 0,78	66,76 70,4-63,3 2,95	**70,58** **71,2-69,9** **0,56**
	MOY+KKM	76,06 77,8-74 1,43	76,84 77,8-75,4 0,96	**85,26** **86,4-83,7** **1,05**	85,18 86,1-84,1 0,79	75,38 76-74,9 0,48	82,24 82,9-81,4 0,58
	TBA (MOY+KKM)	84,24 84,9-83,4 0,60	67,86 70,2-64,9 2,17	67,66 70,2-64,9 2,11	81,46 82,2-80,8 0,63	80,36 85,8-75,4 4,18	**87,56** **88,1-87,2** **0,35**
	DAA (MOY+KKM)	94,40 94,7-93,8 0,36	94,52 94,7-94,4 0,16	93,80 94,7-92,9 0,73	92.90 94,1-91,6 0,97	92,30 93,8-91,4 0,95	**94,58** **95,6-94,1** **0,62**
	TBA(MOY)+ TBA(KKM)	83,40 85,2-82,0 1,33	67,86 70,2-64,9 2,17	70,02 70,7-69,2 0,56	83,10 83,7-82,2 0,60	**88,56** **88,8-88,2** **0,25**	87,14 88,2-86,10 0,77
	DAA(MOY)+ DAA(KKM)	89,80 90,5-88,9 0,65	**93,08** **93,8-92** **0,75**	92,60 93,8-92 0,73	90,74 91,4-89,6 0,80	90,60 90,5-89,6 0,35	90,92 91,4-90,2 0,54

3 sınıflı veri sınıflandırma işlemlerinde sınıflandırma başarısının yanında hata matrisleri de kullanılarak sınıflandırma sonuçları hakkında daha detaylı bilgi edinilmiştir. Her bir öznitelik matrisi için en yüksek sınıflandırma başarısının elde edildiği sınıflandırma sonucuna ilişkin hata matrisleri tablolar halinde aşağıda verilmektedir.

Tablo 13. MOY-RO Sınıflandırma sonuçları

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%64 (41)	%36 (23)	%0 (0)
	Hasta (219)	%16 (35)	%83 (183))	%1 (1)
	Sigara Kullanan (55)	%9 (5)	%0 (0)	%91 (50)

Tablo 14. TBA(MOY)- RO Sınıflandırma sonuçları

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%91 (59)	%7 (4)	%2 (1)
	Hasta (219)	%19 (41)	%72 (158)	%9 (20)
	Sigara Kullanan (55)	%2 (1)	%3 (1)	%96 (53)

Tablo 15. DAA(MOY)-L-DVM Sınıflandırma sonuçar

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%95 (61)	%5 (3)	%0 (0)
	Hasta (219)	%12 (26)	%84 (184)	%4 (9)%0 (0)
	Sigara Kullanan (55)	%0 (0)	%0 (0)	%100 (55)

Tablo 16. KKM- RO Sınıflandırma sonuçları

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%85 (54)	%11 (7)	%4 (3)
	Hasta (219)	%45 (99)	%33 (72)	%22 (48)
	Sigara Kullanan (55)	%10 (5)	%15 (8)2 (1)	%75 (42)

Tablo 17. TBA(KKM)-k-EYK Sınıflandırma sonuçları

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%95 (60)	%5 (4))	%0 (0)
	Hasta (219)	%38 (83)	%44 (96)	%18 (40)
	Sigara Kullanan (55)	%0 (0)	%2 (1)	%98 (54)

Tablo 18. DAA(KKM)- RO Sınıflandırma sonuçları

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%53 (34)	%28 (18)	%19 (12)
	Hasta (219)	%6 (13)	%85 (186))	%9 (20)
	Sigara Kullanan (55)	%11 (6)	%33 (18)	%56 (31)

Tablo 19. (MOY+KKM)-Q-DVM Sınıflandırma

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%72 (58)	%20 (13)	%8 (5)
	Hasta (219)	%0 (0)	%95 (208)	%5 (11)
	Sigara Kullanan (55)	%10 (7)	%26 (15)	%64 (33)

Tablo 20. TBA(MOY+KKM)-RO Sınıflandırma

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%89 (59)	%11 (5)	%0 (0)
	Hasta (219)	%15 (33)	%75 (164)	%10 (22)
	Sigara Kullanan (55)	%0 (0)	%9 (5)	%91 (50)

Tablo 21. DAA(MOY+KKM)-RO Sınıflandırma sonuçları

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%90 (58)	%6 (4)	%4 (2)
	Hasta (219)	%2 (4)	%97 (213)	%1 (2)
	Sigara Kullanan (55)	%4 (2)	%7 (4)	%89 (49)

Tablo 22. TBA(MOY)+TBA(KKM)-k-EYK sınıflandırma sonuçları

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%56 (36)	%43 (27)	%1 (1)
	Hasta (219)	%5 (11)	%95 (208)	%0 (0)
	Sigara Kullanan (55)	%0 (0)	%0 (0)	%100 (55)

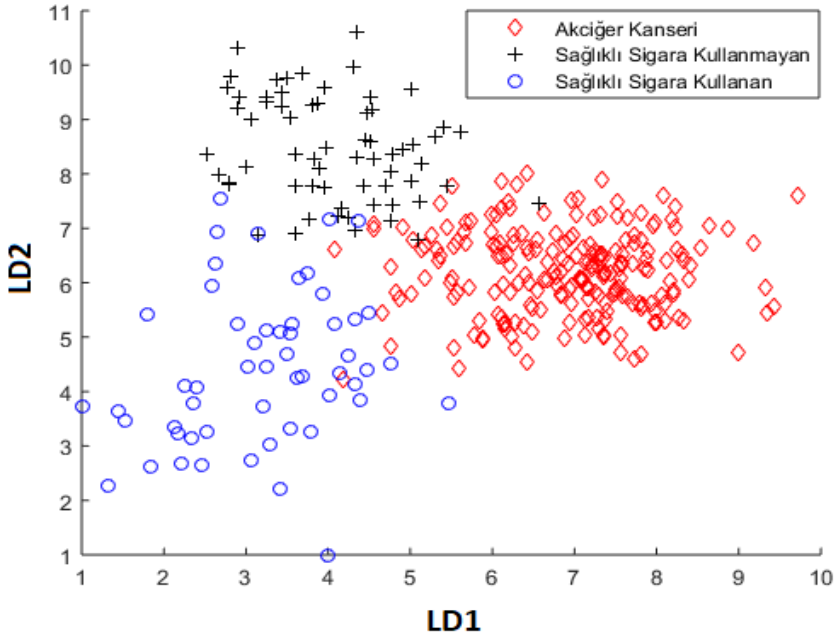
Tablo 23. DAA(MOY)+DAA(KKM)-LDVM Sınıflandırma sonuçları

		Tahmin Edilen Sınıf		
		Sağlıklı (64)	**Hasta (219)**	**Sigara Kullanan (55)**
Gerçek Sınıflar	**Sağlıklı (64)**	%95 (62))	%5 (3)	%0 (0)
	Hasta (219)	%7 (16)	%89 (198)	%4 (5)
	Sigara Kullanan (55)	%0 (0)	%0 (0)	%100 (55)

Tablo 12' de MOY sensör verileri ile KKM sensör verilerinin birlikte kullanılarak DDA yöntemiyle boyutunun azaltılması sonucu en yüksek sınıflandırma başarısı elde edildiği gösterilmişti. Boyutu azaltılan bu verinin dağılım grafiği de Şekil 45'te verilmektedir. Şekil 45'te LD1 ve LD2 ifadeleri DDA yöntemiyle boyutu azaltılarak elde edilen öznitelik matrisinin sırasıyla ilk iki sütununda bulunan öznitelikleri temsil etmektedir. Elde edilen bu dağılım matrisinin şekli veri sınıflandırmada geleneksel sınıflandırma algoritmalarının yanında bulanık mantık yönteminin de kullanılabileceği fikrinin ortaya çıkmasına neden olmuştur. Çalışmamızda kullandığımız veri yapısına bağlı olarak DDA yönteminin veri boyutu azaltırken sınıfları birbirinden uygun şekilde ayırabilmesi bulanık mantık yönteminin de bu çalışmada kullanılmasına olanak sağlamıştır.

3.1.2. BMY Sınıflandırma Sonuçları

BMY' de başarıyı artırmak için üzerinde çalışılan problemin detaylı şekilde incelenmesi, sistem davranışının doğru şekilde çıkarımının yapılmış olması gerekmektedir. Çözümü yapılacak olan problem hakkında ne kadar doğru kararlar verilir ve sistem davranışı ne kadar doğru belirlenirse kullanılacak olan üyelik fonksiyonları ve oluşturulacak olan kural tablosu da o kadar doğru oluşturulur. Bu nedenle çalışma öncesinde dağılım grafiği dikkatli şekilde incelenmiş ve kanser hastalarına ait 3 adet üyelik fonksiyonu kullanılmışken sigara



Şekil 45. DDA(MOY+KKM) verisi dağılım grafiği

kullanmayan ve sigara kullanan sağlıklı bireylere ait 2 adet üyelik fonksiyonu kullanılmasına karar verilmiştir. Kullanılan üyelik fonksiyonu sayısı hem LD1 hem de LD2 öznitelikleri için 7 adet olduğundan dolayı oluşturulan kural tablosunun boyutu (7x7) boyutunda, kural sayısı ise 49 adettir. BMY ile sınıflandırma için gerekli olan kural tablosu Tablo 24' te verilmiştir. Tablo 24'te ◊, akciğer kanseri hastaları, +, sigara kullanmayan sağlıklı bireyleri, *O* ise sigara kullanan sağlıklı bireyleri temsil etmektedir. Kullanılan 5 farklı çeşitte optimizasyon algoritması ile BMY içerisindeki 5 farklı çeşitte üyelik fonksiyonlarının parametreleri optimize edilmiştir. Üyelik fonksiyonlarının optimize edilmesi sonucu BMY ile yapılan sınıflandırma sonuçlarına ilişkin detaylar Tablo 25' te verilmektedir. Her bir optimizasyon algoritması ve üyelik fonksiyonuyla birlikte sınıflandırma işlemi 10 kez tekrarlanmış ve her bir sınıflandırıcıya ait sonuçlar; ortalama başarı, en yüksek başarı, en düşük başarı ve standart sapma değeri şeklinde verilmiştir. Tablo 25' te görüleceği üzere farklı optimizasyon algoritmaları ve farklı üyelik fonksiyonlarının kullanılması sınıflandırma başarısı üzerinde etkili olmaktadır. BMY yöntemiyle yapılan sınıflandırma işleminde en yüksek başarı oranının GA ve çan üyelik fonksiyonun kullanılmasıyla elde edilmiştir

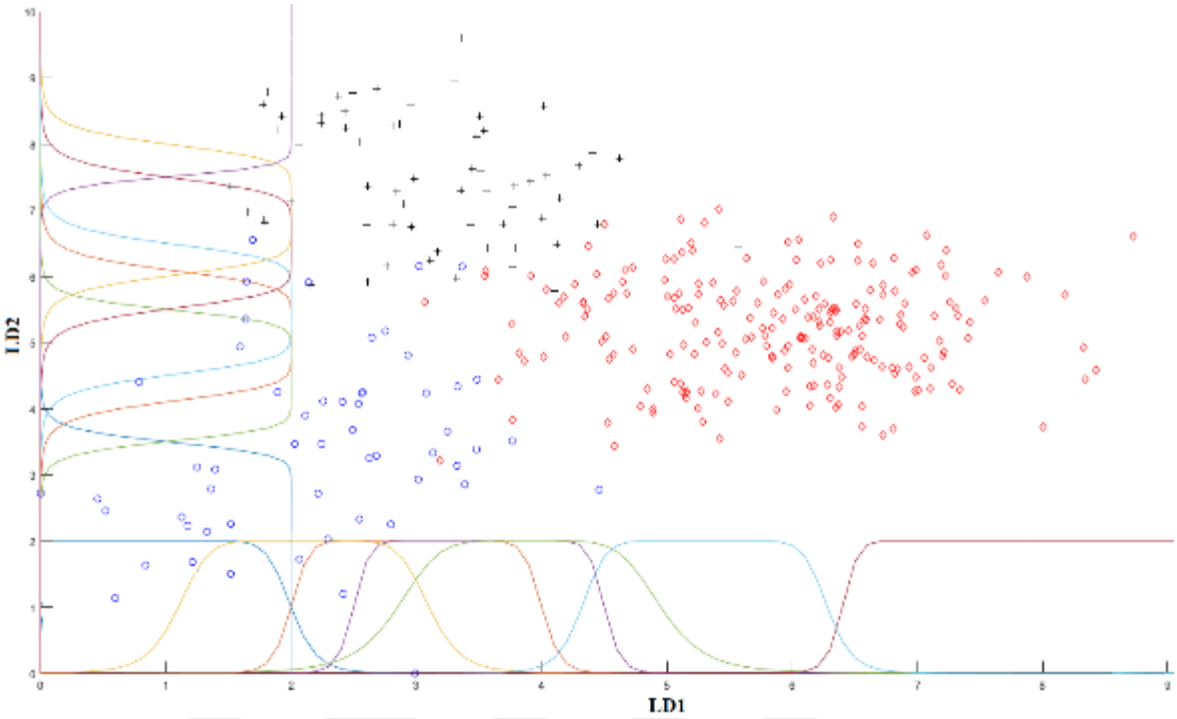
Tablo 24. BMY ile sınıflandırma için oluşturulan kural tablosu.

		LD1						
		O_1	O_2	$+_1$	$+_2$	$◊_1$	$◊_2$	$◊_3$
LD2	O_1	*0*	*0*	*0*	*0*	*0*	◊	◊
	O_2	*0*	*0*	*0*	◊	◊	◊	◊
	$+_1$	+	+	+	+	◊	◊	◊
	$+_2$	+	+	+	+	+	◊	◊
	$◊_1$	*0*	*0*	*0*	◊	◊	◊	◊
	$◊_2$	*0*	*0*	*0*	◊	◊	◊	◊
	$◊_3$	*0*	+	+	+	+	◊	◊

. GA algoritmasının kullanılması sonucu elde edilen çan üyelik fonksiyonları ile dağılım grafiği Şekil 46' da verilmektedir.

Tablo 25. BMY ile yapılan sınıflandırma sonuçları

Üyelik Fonksiyonları	**Optimizasyon Algoritması**				
	PSO	**GA**	**SA**	**IWO**	**AEO**
Gaussian	**95.69 98.07-92.80-2.41**	94.81 97.95-92.07-2.27	92.95 97.36-87.22-3.77	97.27 98.81-94.71-1.66	93.82 97.06-91.18-2.18
Generalized Bell-shaped	97.27 99.26-95.30-1.72	**97.93 100-95.89-1.75**	95.70 99.11-92.62-2.29	97.44 98.56-95.59-1.49	97.56 98.56-95.59-1.37
Pi-shaped	92.98 97.06-91.18-2.33	92.79 97.06-91.18-2.43	92.94 97.06-91.18-2.39	**93.23 97.06-91.18-2.23**	92.65 97.06-91.05-2.54
Trapezoidal	91.74 97.06-88.41-3.35	**92.01 97.06-89.56-3.07**	90.79 97.06-86.67-3.79	89.95 97.06-86.68-4.22	90.30 97.06-86.77-3.95
Triangular	92.30 95.59-89.55-2.22	**94.81 95.59-92.07-2.27**	91.62 95.59-89.71-2.51	92.70 97.06-9.71-2.77	91.47 95.59-89.56-2.63



Şekil 46. Optimizasyon algoritması kullanılarak elde edilen çan üyelik fonksiyonları

4. SONUÇLAR

Bu doktora çalışmasında 8 adet MOY sensör ve 14 adet KKM sensör kullanılarak karma sensör tabanlı bir e-burun devresi geliştirilmiştir. 60 adet akciğer kanseri hastadan, 20 adet sigara kullanmayan gönüllüden ve 20 adet sigara kullanan sağlıklı gönüllüden alınan nefes örnekleriyle e-burun devresinde deneyler gerçekleştirilmiştir. Deneyler sonucu elde edilen veriler incelenerek hem akciğer kanseri- sağlıklı hem de akciğer kanseri-sigara kullanan sağlıklı-sigara kullanmayan sağlıklı gönüllülerin verilerini birbirlerinden en iyi ayırt etmeyi sağlayacak öznitelikler belirlenmiştir. Elde edilen öznitelik matrisi, öncelikle boyutu herhangi bir boyut azaltma algoritmasıyla azaltılmadan sınıflandırılmıştır. Ardından DDA ve TBA boyut azaltma algoritmalarının sınıflandırma başarısı üzerindeki etkisini görmek için öznitelik matrisinin boyutu azaltılarak veri sınıflandırma gerçekleştirilmiştir. Veri sınıflandırma gerçekleştirilirken öncelikle MOY ve KKM sensör verilerinden elde edilen öznitelikler ayrı ayrı sınıflandırılmış ardından bu iki öznitelik matrisi birlikte kullanılarak veriler sınıflandırılmıştır. Elde edilen sınıflandırma sonuçları, bu çalışmanın başlangıcındaki, farklı tip sensörlerin birlikte kullanımının akciğer kanserinin tespitini artırabileceği fikrini destekler niteliktedir. Gerçekleştirilen çalışmalar incelendiğinde DDA boyut azaltma algoritmasının sınıflandırma başarısı üzerinde önemli ölçüde etkisi olduğu görülmüştür. İki sınıflı veri sınıflandırmada en yüksek sınıflandırma başarısı %95,36 ile DDA(MOY+KKM) öznitelik matrisinin kullanılmasıyla elde edilmiştir. Üç sınıflı veri sınıflandırma işleminde öznitelik matrisinin boyutu DDA yöntemiyle azaltıldıktan sonra oluşan sınıflar arası dağılım BMY yönteminin de sınıflandırıcı kolay şekilde kullanılabilmesini sağlamıştır. BMY yönteminin kullanılması sonucu elde edilen ortalama %97,93 değerindeki sınıflandırma başarısı bu doktora çalışmasını e-burun ile akciğer kanseri tespiti çalışmaları arasında ön plana çıkarmaktadır. Bu başarının elde edilmesi için BMY yöntemindeki üyelik fonksiyonları parametrelerinin farklı optimizasyon algoritmaları ile optimize edilmesi sağlanmıştır.

Akciğer kanseri gibi dünyadaki en ölümcül kanser türünün e-burun ile tespitine yönelik yapılan bu çalışmada elde edilen sonuçlar geliştirilen e-burun devresinin uygulamada kullanılabilirliğini kanıtlar niteliktedir. Bu çalışma, karma sensör tabanlı e-burun kullanılarak akciğer kanseri tespitine yönelik Türkiye'deki ilk ve öncü bir çalışmadır. Çalışmamızın pratikte akciğer kanseri tespitinde geniş bir uygulama alanı bulacağına inanıyoruz.

5. ÖNERİLER

Doktora tezi olarak sunulan bu çalışmada elde edilen sonuçlar ilk aşamada akciğer kanserinin tespiti konusunda hastalara tanı konulmadan önce yapılan testlerdeki harcamaların önemli oranda azaltması öngörülmektedir. Sadece nefes testi ile hastaya hiç bir şekilde zarar vermeden tanı konulabilecektir. Bununla birlikte akciğer kanserinin erken evrelerde tespit edilebilmesi durumunda, bireylerin yaşam kalitesi artacak, ölüm oranları ve tedavi giderleri azalacaktır. Böylece; bu sistemin hayata geçirilmesinin, aile bütçesine ve dolayısıyla ülke ekonomisine üstün katkılar sağlayacağı düşünülmektedir. Tez çalışması boyunca yapılan çalışmalar ile gerçekleştirilen e-burun devresiyle daha doğru sonuçlar alınması için çalışmaya katılan gönüllü sayısını daha artması gerektiği düşünülmektedir. Böylece çok daha fazla sayıda veri ile eğitilecek olan sistem yeni gelen veriler için de daha kapsayıcı sonuçlar üreteceği düşünülmektedir. Özellikle erken evrelerde akciğer kanseri hastalığı bulunan gönüllülerden alınan nefes örnekleriyle deneyler yapılması e-burun ile akciğer kanserinin erken evrelerde tespit edilmesine katkı sağlayacaktır. Bu şekilde en ölümcül kanser türü olan akciğer kanserinin erken evrelerde tespit edilip ivedi şekilde tedavi işlemine başlanması sağlanacaktır.

Ayrıca bu proje çalışmasında elde edilen deneyimler ve bulgular, sadece akciğer kanserini değil, nefes örnekleri ile birçok hastalığın tespitinde kullanılabilecek, kapsamlı bir elektronik burunun geliştirilebilmesi çalışmalarına önemli bir taban oluşturabileceği düşünülmektedir.

6. KAYNAKLAR

Alar, T., & Şahin, E. M. (2012). Akciğer kanseri: birinci basamakta tanı, tedavi ve korunma Lung cancer: Diagnosis, treatment and prevention in primary care. Smyrna Tıp Derg, 68-74.

Altaş, İ. H., & Mantık, B. (1999). Bulanıklık Kavramı, Enerji, Elektrik, Elektromekanik-3e.

Anand, M. J., & Sridhar, V. (2018). Characterisation of gas sensor array for milk spoilage and diseases detection. International Journal of Electronics, Electrical and Computational System, 7(2), 48-52.

Anwar, F., Hussain, A. I., Iqbal, S., & Bhanger, M. I. (2007). Enhancement of the oxidative stability of some vegetable oils by blending with Moringa oleifera oil. Food chemistry, 103(4), 1181-1191.

Anwar, F., Hussain, A. I., Iqbal, S., & Bhanger, M. I. (2007). Enhancement of the oxidative stability of some vegetable oils by blending with Moringa oleifera oil. Food chemistry, 103(4), 1181-1191.

Atasoy, A., Ozsandikcioglu, U., & Guney, S. (2015, November). Fish freshness testing with artificial neural networks. In 2015 9th International Conference on Electrical and Electronics Engineering (ELECO) (pp. 700-704). IEEE.

Baldini, C., Billeci, L., Sansone, F., Conte, R., Domenici, C., & Tonacci, A. (2020). Electronic nose as a novel method for diagnosing cancer: a systematic review. Biosensors, 10(8), 84.

Behera, B., Joshi, R., Vishnu, G. A., Bhalerao, S., & Pandya, H. J. (2019). Electronic nose: A non-invasive technology for breath analysis of diabetes and lung cancer patients. Journal of breath research, 13(2), 024001.

Bircan, H. A., Öztürk, Ö., Şahin, Ü., Özaydın, N., & Akkaya, A. (2005). Akciğer kanseri tanısı alan olgularımızın Retrospektif değerlendirilmesi. SDÜ Tıp Fakültesi Dergisi, 12(3), 1-6.

Blanco-Rodríguez, A., Camara, V. F., Campo, F., Becherán, L., Durán, A., Vieira, V. D., ... & Garcia-Ramirez, A. R. (2018). Development of an electronic nose to characterize odours emitted from different stages in a wastewater treatment plant. Water research, 134, 92-100.

Blandin Knight, S., Crosbie, P. A., Balata, H., Chudziak, J., Hussell, T., & Dive, C. (2017). Progress and prospects of early detection in lung cancer. Open biology, 7(9), 170070.

Blatt, R., Bonarini, A., Calabro, E., Della Torre, M., Matteucci, M., & Pastorino, U. (2007, August). Lung cancer identification by an electronic nose based on an array of MOS sensors. In 2007 International joint conference on neural networks (pp. 1423-1428). IEEE.

Bona, E., da Silva, R. S. D. S. F., Borsato, D., & Bassoli, D. G. (2011). Optimized neural network for instant coffee classification through an electronic nose. International Journal of Food Engineering, 7(6).

Bozkurtlar, E., & Kaya, H. (2018). Molecular pathology of lung cancer. Nukleer Tıp Seminerleri, 4(1), 26.

Breiman, L. (2001). Random forests. Machine learning, 45, 5-32.

Breiman, L. (2002). Manual on setting up, using, and understanding random forests v3. 1. Statistics Department University of California Berkeley, CA, USA, 1(58), 3-42.

Bruins, M., Rahim, Z., Bos, A., van de Sande, W. W., Endtz, H. P., & van Belkum, A. (2013). Diagnosis of active tuberculosis by e-nose analysis of exhaled air. Tuberculosis, 93(2), 232-238.

Chen, L. Y., Wu, C. C., Chou, T. I., Chiu, S. W., & Tang, K. T. (2018). Development of a dual MOS electronic nose/camera system for improving fruit ripeness classification. Sensors, 18(10), 3256.

Chen, W., Xia, C., Zheng, R., Zhou, M., Lin, C., Zeng, H., ... & He, J. (2019). Disparities by province, age, and sex in site-specific cancer burden attributable to 23 potentially modifiable risk factors in China: a comparative risk assessment. The Lancet Global Health, 7(2), e257-e269.

Cheng, Z. J., Warwick, G., Yates, D. H., & Thomas, P. S. (2009). An electronic nose in the discrimination of breath from smokers and non-smokers: a model for toxin exposure. Journal of breath research, 3(3), 036003.

Choe, E., & Min, D. B. (2007). Chemistry of deep-fat frying oils. Journal of food science, 72(5), R77-R86.

Chung, H., & Shin, K. S. (2020). Genetic algorithm-optimized multi-channel convolutional neural network for stock market prediction. Neural Computing and Applications, 32, 7897-7914.

Cui, S., Inocente, E. A. A., Zhu, H., Acosta, N., Ling, P. P., & Keener, H. M. (2018). Development of portable E-nose system for early diagnosis of insect-stressed tomato plants. In 2018 ASABE Annual International Meeting (p. 1). American Society of Agricultural and Biological Engineers.

Cutz, J. C., Craddock, K. J., Torlakovic, E., Brandao, G., Carter, R. F., Bigras, G., ... & Tsao, M. S. (2014). Canadian anaplastic lymphoma kinase study: a model for multicenter standardization and optimization of ALK testing in lung cancer. *Journal of Thoracic Oncology*, *9*(9), 1255-1263.

Davies, S., Spanel, P., & Smith, D. (1997). Quantitative analysis of ammonia on the breath of patients in end-stage renal failure. *Kidney international*, *52*(1), 223-228.

De Castro, M. L., & Fernandez-Peralbo, M. A. (2012). Analytical methods based on exhaled breath for early detection of lung cancer. TrAC Trends in Analytical Chemistry, 38, 13-20.

Dutta, L., Talukdar, C., Hazarika, A., & Bhuyan, M. (2017). A novel low-cost hand-held tea flavor estimation system. IEEE Transactions on Industrial Electronics, 65(6), 4983-4990.

Enderby, B., Smith, D., Carroll, W., & Lenney, W. (2009). Hydrogen cyanide as a biomarker for Pseudomonas aeruginosa in the breath of children with cystic fibrosis. Pediatric pulmonology, 44(2), 142-147.

ERBAYCU, A. E. Akciğer Kanserinde Epidemiyoloji ve Risk Faktörleri.

Fend, R., Kolk, A. H., Bessant, C., Buijtels, P., Klatser, P. R., & Woodman, A. C. (2006). Prospects for clinical application of electronic-nose technology to early detection of Mycobacterium tuberculosis in culture and sputum. Journal of Clinical Microbiology, 44(6), 2039-2045.

Fens, N., Zwinderman, A. H., van der Schee, M. P., de Nijs, S. B., Dijkers, E., Roldaan, A. C., ... & Sterk, P. J. (2009). Exhaled breath profiling enables discrimination of chronic obstructive pulmonary disease and asthma. American journal of respiratory and critical care medicine, 180(11), 1076-1082.

Gasparri, R., Santonico, M., Valentini, C., Sedda, G., Borri, A., Petrella, F., ... & Spaggiari, L. (2016). Volatile signature for the early diagnosis of lung cancer. Journal of breath research, 10(1), 016007.

Gautschi, O., Milia, J., Filleron, T., Wolf, J., Carbone, D. P., Owen, D., ... & Drilon, A. (2017). Targeting RET in patients with RET-rearranged lung cancers: results from the global, multicenter RET registry. Journal of Clinical Oncology, 35(13), 1403.

Guo, Y., Zeng, H., Zheng, R., Li, S., Barnett, A. G., Zhang, S., ... & Williams, G. (2016). The association between lung cancer incidence and ambient air pollution in China: A spatiotemporal analysis. Environmental research, 144, 60-65.

Haddi, Z., Amari, A., Alami, H., El Bari, N., Llobet, E., & Bouchikhi, B. E. N. A. C. H. I. R. (2011). A portable electronic nose system for the identification of cannabis-based drugs. Sensors and Actuators B: Chemical, 155(2), 456-463.

Haddi, Z., El Barbri, N., Tahri, K., Bougrini, M., El Bari, N., Llobet, E., & Bouchikhi, B. (2015). Instrumental assessment of red meat origins and their storage time using electronic sensing systems. Analytical Methods, 7(12), 5193-5203.

Huang, H., Zhou, J., Chen, S., Zeng, L., & Huang, Y. (2004). A highly sensitive QCM sensor coated with Ag+-ZSM-5 film for medical diagnosis. Sensors and Actuators B: Chemical, 101(3), 316-321.

Ismail, M., Majeed, A. A., & Albastaki, Y. A. (2018). A framework for an artificial-neural-network-based electronic nose. In Electronic Nose Technologies and Advances in Machine Olfaction (pp. 1-24). IGI Global.

Izci, D., Hekimoğlu, B., & Ekinci, S. (2022). A new artificial ecosystem-based optimization integrated with Nelder-Mead method for PID controller design of buck converter. Alexandria Engineering Journal, 61(3), 2030-2044.

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112, p. 18). New York: springer.

Jantus-Lewintre, E., Usó, M., Sanmartín, E., & Camps, C. (2012). Update on biomarkers for the detection of lung cancer. Lung Cancer: Targets and Therapy, 21-29.

Jasiński, G., Woźniak, Ł., Kalinowski, P., & Jasiński, P. (2018). Evaluation of the Electronic Nose Used for Monitoring Environmental Pollution.

Jemal, A., Siegel, R., Xu, J., & Ward, E. (2010). Cancer statistics, 2010. CA: a cancer journal for clinicians, 60(5), 277-300.

Ju, L., Han, M., Zhao, C., & Li, X. (2016). EGFR, KRAS and ROS1 variants coexist in a lung adenocarcinoma patient. Lung Cancer, 95, 94-97.

Karki S.,, Yin Y-j., Samanai N., Zhang J-X. , Pradhan D., Deuja S.S., Karki R., Breathe analyzer and its importance for the early detection of lung cancer, Sky Journal of Medicine and Medical Sciences, 1(2), 7-9, 2013

Karki, S., Yj, Y., Samanai, N., Zhang, J. X., & Pradhan, D. (2013). Breathe analyzer and its importance for the early detection of lung cancer. Sky J Med Med Sci, 1, 7-9.

Käsmann, L., Dietrich, A., Staab-Weijnitz, C. A., Manapov, F., Behr, J., Rimner, A., ... & Belka, C. (2020). Radiation-induced lung toxicity–cellular and molecular mechanisms of pathogenesis, management, and literature review. Radiation Oncology, 15(1), 1-16.

Kavzoğlu, T., & Çölkesen, İ. (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, *144*(7), 73-82.

Kennedy, J., Eberhart, R.C. and Shi, Y. (2001) Swarm Intelligence. Morgan Kaufmann Publishers, San Francisco.

Kim, E. K., Kim, K. A., Lee, C. Y., & Shim, H. S. (2017). The frequency and clinical impact of HER2 alterations in lung adenocarcinoma. PloS one, 12(2), e0171280.

Kim, H. J., & Shin, K. S. (2007). A hybrid approach based on neural networks and genetic algorithms for detecting temporal patterns in stock markets. Applied Soft Computing, 7(2), 569-576.

Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). Optimization by Simulated Annealing. Science, 220(4598), 671–680. http://www.jstor.org/stable/1690046

Kokoszka, J., Nelson, R. L., Swedler, W. I., Skosey, J., & Abcarian, H. (1993). Determination of inflammatory bowel disease activity by breath pentane analysis. Diseases of the colon & rectum, 36, 597-601.

Leunis, N., Boumans, M. L., Kremer, B., Din, S., Stobberingh, E., Kessels, A. G., & Kross, K. W. (2014). Application of an electronic nose in the diagnosis of head and neck cancer. The Laryngoscope, 124(6), 1377-1381.

Li, W., Liu, H. Y., Jia, Z. R., Qiao, P. P., Pi, X. T., Chen, J., & Deng, L. H. (2014). Advances in the early detection of lung cancer using analysis of volatile organic compounds: from imaging to sensors. Asian Pacific Journal of Cancer Prevention, 15(11), 4377-4384.

Li, W., Liu, H., Xie, D., He, Z., & Pi, X. (2017). Lung cancer screening based on type-different sensor arrays. Scientific reports, 7(1), 1969.

Lima, R. S., Danielski, G. C., & Pires, A. C. S. (2018). Mastitis detection and prediction of milk composition using gas sensor and electrical conductivity. Food and bioprocess technology, 11, 551-560.

Lin, S., & Zhang, X. (2016). A rapid and novel method for predicting nicotine alkaloids in tobacco through electronic nose and partial least-squares regression analysis. Analytical Methods, 8(7), 1609-1617.

Lynch, T. J., Bell, D. W., Sordella, R., Gurubhagavatula, S., Okimoto, R. A., Brannigan, B. W., ... & Haber, D. A. (2004). Activating mutations in the epidermal growth factor receptor underlying responsiveness of non–small-cell lung cancer to gefitinib. New England Journal of Medicine, 350(21), 2129-2139.

Macías, M. M., Agudo, J. E., Manso, A. G., Orellana, C. J. G., Velasco, H. M. G., & Caballero, R. G. (2013). A compact and low cost electronic nose for aroma detection. Sensors, 13(5), 5528-5541.

Maiers, J., & Sherif, Y. S. (1985). Applications of fuzzy set theory. IEEE Transactions on Systems, Man, and Cybernetics, (1), 175-189.

Makimori, G. Y. F., & Bona, E. (2019). Commercial instant coffee classification using an electronic nose in tandem with the ComDim-LDA approach. Food Analytical Methods, 12, 1067-1076.

Marcus, P. M., Bergstralh, E. J., Zweig, M. H., Harris, A., Offord, K. P., & Fontana, R. S. (2006). Extended lung cancer incidence follow-up in the Mayo Lung Project and overdiagnosis. Journal of the National Cancer Institute, 98(11), 748-756.

Mazzone, P. J., Obuchowski, N., Phillips, M., Risius, B., Bazerbashi, B., & Meziane, M. (2013). Lung cancer screening with computer aided detection chest radiography: design and results of a randomized, controlled trial. PloS one, 8(3), e59650.

Mazzone, P. J., Wang, X. F., Xu, Y., Mekhail, T., Beukemann, M. C., Na, J., ... & Sasidhar, M. (2012). Exhaled breath analysis with a colorimetric sensor array for the identification and characterization of lung cancer. Journal of Thoracic Oncology, 7(1), 137-142.

McLoud, T. C. (2002). Imaging techniques for diagnosis and staging of lung cancer. Clinics in chest medicine, 23(1), 123-136.

Mehrad, M., Roy, S., Bittar, H. T., & Dacic, S. (2018). Next-generation sequencing approach to non–small cell lung carcinoma yields more actionable alterations. Archives of pathology & laboratory medicine, 142(3), 353-357.

Miekisch, W., Schubert, J. K., & Noeldge-Schomburg, G. F. (2004). Diagnostic potential of breath analysis—focus on volatile organic compounds. Clinica chimica acta, 347(1-2), 25-39.

Mohamed, E. I., Bruno, E., Linder, R., Alessandrini, M., Di Girolamo, A., Pöppl, S. J., ... & De Lorenzo, A. (2003, January). A novel method for diagnosing chronic rhinosinusitis based on an electronic nose. In Anales otorrinolaringológicos ibero-americanos (Vol. 30, No. 5, pp. 447-457).

National Lung Screening Trial Research Team. (2011). Reduced lung-cancer mortality with low-dose computed tomographic screening. New England Journal of Medicine, 365(5), 395-409.

Nooreldeen, R., & Bach, H. (2021). Current and future development in lung cancer diagnosis. International journal of molecular sciences, 22(16), 8661.

Oken, M. M., Hocking, W. G., Kvale, P. A., Andriole, G. L., Buys, S. S., Church, T. R., ... & PLCO Project Team, F. T. (2011). Screening by chest radiograph and lung cancer mortality: the Prostate, Lung, Colorectal, and Ovarian (PLCO) randomized trial. Jama, 306(17), 1865-1873.

Özdoğan, M. (2022, Kasım 17). 4. Evre Kanser, Metastaz ve Metastatik Nedir, Metastaz Belirtileri, Kanser Neden Metastaz Yapar? https://www.drozdogan.com/4-evre-kanser-nedir-metastaz-ne-demektir-kanser-neden-metastaz-yapar/ adresinden alınmıştır.

Palasuek, R., Seesa-Ard, T., Kunarak, C., & Kerdcharoen, T. (2015, June). Electronic nose for water monitoring: The relationship between wastewater quality indicators and odor. In 2015 12th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON) (pp. 1-5). IEEE.

Pauling, L., Robinson, A. B., Teranishi, R., & Cary, P. (1971). Quantitative analysis of urine vapor and breath by gas-liquid partition chromatography. Proceedings of the National Academy of Sciences, 68(10), 2374-2376.

Pearce, T. C., & Sanchez-Montanes, M. (2003). Chemical sensor array optimization: geometric and information theoretic approaches. Handbook of Artificial Olfaction Machines, 347-376.

Peng, G., Hakim, M., Broza, Y. Y., Billan, S., Abdah-Bortnyak, R., Kuten, A., ... & Haick, H. (2010). Detection of lung, breast, colorectal, and prostate cancers from exhaled breath using a single array of nanosensors. British journal of cancer, 103(4), 542-551.

Planchard, D., Besse, B., Groen, H. J., Souquet, P. J., Quoix, E., Baik, C. S., ... & Johnson, B. E. (2016). An open-label phase 2 trial of dabrafenib plus trametinib in patients

with previously treated BRAF V600E–mutant metastatic non-small cell lung cancer. The Lancet. Oncology, 17(7), 984.

Poli, D., Goldoni, M., Corradi, M., Acampa, O., Carbognani, P., Internullo, E., ... & Mutti, A. (2010). Determination of aldehydes in exhaled breath of patients with lung cancer by means of on-fiber-derivatisation SPME–GC/MS. Journal of Chromatography B, 878(27), 2643-2651.

Rabeau, A., Rouquette, I., Vantelon, J. M., Taranchon-Clermont, E., & Mazieres, J. (2016). Interest of crizotinib in a lung cancer patient with de novo amplification of MET. Revue des maladies respiratoires, 34(1), 57-60.

Ren, Y., Ramaswamy, H. S., Li, Y., Yuan, C., & Ren, X. (2018). Classification of impact injury of apples using electronic nose coupled with multivariate statistical analyses. Journal of Food Process Engineering, 41(5), e12698.

Rosell, R., Carcereny, E., Gervais, R., Vergnenegre, A., Massuti, B., Felip, E., ... & Paz-Ares, L. (2012). Erlotinib versus standard chemotherapy as first-line treatment for European patients with advanced EGFR mutation-positive non-small-cell lung cancer (EURTAC): a multicentre, open-label, randomised phase 3 trial. The lancet oncology, 13(3), 239-246.

Sànchez, C., Lozano, J., Santos, J. P., Azabal, A., & Ruiz-Valdepeñas, S. (2018, November). Discrimination of aromas in beer with electronic nose. In 2018 Spanish Conference on Electron Devices (CDE) (pp. 1-4). IEEE.

Saraoğlu, H. M., Selvi, A. O., Ebeoğlu, M. A., & Taşaltin, C. (2013). Electronic nose system based on quartz crystal microbalance sensor for blood glucose and HbA1c levels from exhaled breath odor. IEEE Sensors Journal, 13(11), 4229-4235.

Scheepers, M. H., Al-Difaie, Z., Brandts, L., Peeters, A., van Grinsven, B., & Bouvy, N. D. (2022). Diagnostic performance of electronic noses in cancer diagnoses using exhaled breath: a systematic review and meta-analysis. Jama network open, 5(6), e2219372-e2219372.

Scholpp, J., Schubert, J. K., Miekisch, W., & Geiger, K. (2002). Breath markers and soluble lipid peroxidation markers in critically ill patients.

Sekhar, P. K., Brosha, E. L., Mukundan, R., & Garzon, F. (2010). Chemical sensors for environmental monitoring and homeland security. The Electrochemical Society Interface, 19(4), 35.

Sharma, V., & Tripathi, A. K. (2022). A systematic review of meta-heuristic algorithms in IoT based application. Array, 14, 100164.

Shi, Z. B., Yu, T., Zhao, Q., Li, Y., & Lan, Y. B. (2008). Comparison of algorithms for an electronic nose in identifying liquors. Journal of Bionic Engineering, 5(3), 253-257.

Straume, T., J Loftus, D., Li, J., A Coleman, M., E Davis, C., A McMonigal, K., ... & K Singh, A. (2013). Biomarker-detection technologies for comprehensive medical

diagnosis during deep-space missions. Recent Patents on Space Technology, 3(1), 13-23.

Şimşir, Ş., & Taşpınar, N. (2021). An improved PTS scheme based on a novel discrete invasive weed optimization algorithm for PAPR reduction in the UFMC signal. Neural Computing and Applications, 33(23), 16403-16424.

Tan, J., & Kerr, W. L. (2018). Determining degree of roasting in cocoa beans by artificial neural network (ANN)-based electronic nose system and gas chromatography/mass spectrometry (GC/MS). Journal of the Science of Food and Agriculture, 98(10), 3851-3859.

Timm, N. H. (Ed.). (2002). Applied multivariate analysis. New York, NY: Springer New York.

Timsorn, K., Thoopboochagorn, T., Lertwattanasakul, N., & Wongchoosuk, C. (2016). Evaluation of bacterial population on chicken meats using a briefcase electronic nose. Biosystems Engineering, 151, 116-125.

Tirzïte, M., Bukovskis, M., Strazda, G., Jurka, N., & Taivans, I. (2018). Detection of lung cancer with electronic nose and logistic regression analysis. Journal of breath research, 13(1), 016006.

URL-1. (2020, Kasım 24). Solunum Sistemi Organları ve Görevleri Nelerdir? https://www.bilgial.com/solunum-sistemi-organlari-ve-gorevleri-nelerdir/ adresidnen alınmıştır.

URL-2. (2019, Mart 04). Solunum Organları. https://www.biyolojidersim.com/solunum-organlari/ adresidnen alınmıştır.

Valdez, L. F., & Gutiérrez, J. M. (2016). Chocolate classification by an electronic nose with pressure controlled generated stimulation. Sensors, 16(10), 1745.

Van de Goor, R., van Hooren, M., Dingemans, A. M., Kremer, B., & Kross, K. (2018). Training and validating a portable electronic nose for lung cancer screening. Journal of Thoracic Oncology, 13(5), 676-681.

Wang, J. (2007). Electrochemical sensing of explosives. Electroanalysis: An International Journal Devoted to Fundamental and Practical Aspects of Electroanalysis, 19(4), 415-423.

Wang, M., Luo, X., Xu, S., Liu, W., Ding, F., Zhang, X., ... & Wang, W. (2019). Trends in smoking prevalence and implication for chronic diseases in China: serial national cross-sectional surveys from 2003 to 2013. The Lancet Respiratory Medicine, 7(1), 35-45.

Wei, Z., Xiao, X., Wang, J., & Wang, H. (2017). Identification of the rice wines with different marked ages by electronic nose coupled with smartphone and cloud storage platform. Sensors, 17(11), 2500.

Wilson, A. D. (2013). Diverse applications of electronic-nose technologies in agriculture and forestry. Sensors, 13(2), 2295-2348.

Wojnowski, W., Majchrzak, T., Dymerski, T., Gębicki, J., & Namieśnik, J. (2017). Portable electronic nose based on electrochemical sensors for food quality assessment. Sensors, 17(12), 2715.

Wong, D. M., Fang, C. Y., Chen, L. Y., Chiu, C. I., Chou, T. I., Wu, C. C., ... & Tang, K. T. (2018, April). Development of a breath detection method based E-nose system for lung cancer identification. In 2018 IEEE International Conference on Applied System Invention (ICASI) (pp. 1119-1120). IEEE.

Woodard, G. A., Jones, K. D., & Jablons, D. M. (2016). Lung cancer staging and prognosis. Lung Cancer: Treatment and Research, 47-75.

Yılmaz, Ü. (2018). Treatment approaches in lung cancer. Nukleer Tıp Seminerleri, 4(1), 32.

Yinon, J. (Ed.). (2011). Counterterrorist detection techniques of explosives. Elsevier.

Yu, H., Wang, J., Xiao, H., & Liu, M. (2009). Quality grade identification of green tea using the eigenvalues of PCA based on the E-nose signals. Sensors and Actuators B: Chemical, 140(2), 378-382.

Zadeh, L. A. (1969). Biological application of the theory of fuzzy sets and systems. In *The Proceedings of an International Symposium on Biocybernetics of the Central Nervous System* (pp. 199-206). London: Little, Brown and Comp..

Zadeh, L. A. (1973). Outline of a new approach to the analysis of complex systems and decision processes. IEEE Transactions on systems, Man, and Cybernetics, (1), 28-44.

Zadeh, L. A. (1975). The concept of a linguistic variable and its application to approximate reasoning—I. *Information sciences*, *8*(3), 199-249.

ÖZGEÇMİŞ

İlköğrenimini Namık Kemal İlköğretim Okulu'nda bitirdikten sonra lise eğitimini 2008 yılında Trabzon (YDA) Lisesi'nde tamamladı. 2009-20010 öğretim yılında Karadeniz Teknik Üniversitesi Elektrik Elektronik Mühendisliği bölümünde lisans eğitimine başladı. 2013 yılında bu bölümden mezun oldu. Aynı yıl Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik ve Bilgisayar Bilimleri Anabilim dalında tezli yüksek lisans programına başladı. 2016 yılında "Farklı Kokuların Yapay Sinir Ağları ve Bulanık Mantık Yöntemleriyle Sınıflandırılması" başlıklı yüksek lisans tezini sunmasının ardından doktora eğitimine başladı. 2013-2019 yılları arasında itibaren Karadeniz Teknik Üniversitesi Elektrik Elektronik Mühendisliği Bölümü'nde araştırma görevlisi olarak görev yapmıştır. 2019 yılından itibaren Karadeniz Teknik Üniversitesi Merkezi Araştırma Laboratuvarı'nda Öğretim Görevlisi olarak görev yapmaktadır. İyi derece İngilizce bilmektedir.

SCI, SSCI VE AHCI İNDEKSLERİNE GİREN DERGİLERDE YAYINLANAN MAKALELER

ÖZSANDIKCIOĞLU, Ü., & ATASOY, A. (2023). Breath analysis for detection of lung cancer with hybrid sensor-based electronic nose.*Turkish Journal of Electrical Engineering and Computer Sciences*,*31*(3), 550-565.

DİĞER DERGİLERDE YAYINLANAN MAKALELER

ÖZSANDIKCIOĞLU Ü., ATASOY A., KABLAN Y., SEVİM Y.,&AYKUT M. (2018). EEG İşaretlerinde Boyut İndirgeme Algoritmalarının Karşılaştırılması. *Akıllı Sistemler ve Uygulamaları Dergisi,*1(1), 140-144.

PROJELER

Taşınabilir Elektronik Burun ile Akciğer Kanseri Hastalığının Erken Tespiti, (2016-2020). TÜBİTAK 3001 Projesi.

Sensörler ile Ankastre Fırında Gıda Tanıma ve Yanmayı Önleme (2021). Vestel Beyaz Eşya Sanayii Araştırma Projesi

HAKEMLİ KONGRE / SEMPOZYUM BİLDİRİ KİTAPLARINDA YER ALAN YAYINLAR

Kazdal, E., Atasoy, A., & Özsandıkcıoğlu, Ü., (2021). E-Burun Kullanılarak Aynı Hasat Dönemindeki Farklı Kalitelere Sahip Siyah Çayların Sınıflandırılması . Uluslararası Mühendislik, Doğa ve Sosyal Bilimler Sempozyumu (ISENS-21) (pp.285-289). Batman, Turkey

Kablan, Y., Atasoy, A., & Özsandikcioğlu, Ü. (2018, May). Classification of different black teas with E-nose. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

Özsandıkcıoğlu, Ü., Atasoy, A., & Yapıcı, Ş. (2018, June). Hybrid Sensor Based E-Nose For Lung Cancer Diagnosis. In 2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA) (pp. 1-5). IEEE.

Özsandikcioğlu, Ü., Yapıcı, Ş., & Atasoy, A. (2018, July). Classification of Different Breath Samples Utilizing E-Nose System. In 2018 41st International Conference on Telecommunications and Signal Processing (TSP) (pp. 1-5). IEEE.

Yapici, S., Özsandikcioğlu, Ü., & Atasoy, A. (2018, May). Performance analysis of dimension reduction algorithms on EEG signals. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

Özsandikcioğlu, Ü., Atasoy, A., & Yapici, Ş. (2018, May). Diagnosis of lung cancer with E-nose. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

Kablan, Y., Özsandıkçıoğlu, Ü., & Atasoy, A. (2017, May). Classification of EEG signals caused by imagining hand movements. In 2017 25th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

Özsandıkçıoğlu, Ü., Atasoy, A., & Altaş, İ. H. (2015, September). The effects of different membership functions on the system output. In 2015 International Symposium on Innovations in Intelligent SysTems and Applications (INISTA) (pp. 1-4). IEEE.

Özsandıkçıoğlu, Ü., Atasoy, A., & Güney, S. (2015, May). Classification of different objects with Artificial Neural Networks using electronic nose. In 2015 23nd Signal Processing and Communications Applications Conference (SIU) (pp. 815-818). IEEE.

Atasoy, A., Ozsandikcioglu, U., & Guney, S. (2015, November). Fish freshness testing with artificial neural networks. In 2015 9th International Conference on Electrical and Electronics Engineering (ELECO) (pp. 700-704). IEEE.

Özsandıkcıoğlu, Ü., Atasoy, A., & Yapıcı, Ş., (2018). Detection of Lung Cancer with QCM Sensors Based E-Nose . 7th International Conference on Advanced Technology & Sciences, (pp.1-4). Antalya, Turkey

Kablan, Y., Atasoy, A., & Özsandıkcıoğlu, Ü., (2018). Classification of Different Black Teas with E-Nose . 7th International Conference on Advanced Technology & Sciences (pp.1-4). Antalya, Turkey

Yapıcı, Ş., Atasoy, A., & Özsandıkcıoğlu, Ü., (2018). ‘Diagnosis of Hearth Diseases by Using Cleveland Dataset . 7th International Conference on Advanced Technology & Sciences (pp.1-4). Antalya, Turkey