T.C.

TRAKYA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

MİKRODALGA ÖLÇÜM VERİLERİNDEN MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK PATLAYICI MADDE TESPİTİ

EBRU EFEOĞLU

DOKTORA TEZİ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Tez Danışmanı: PROF. DR. GÜRKAN TUNA

EDİRNE-2021

Ebru EFEOĞLU'nun hazırladığı "**MİKRODALGA ÖLÇÜM VERİLERİNDEN MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK PATLAYICI MADDE TESPİTİ**" başlıklı bu tez, tarafımızca okunmuş, kapsam ve niteliği açısından **Bilgisayar Mühendisliği** Anabilim Dalında bir **Doktora tezi** olarak kabul edilmiştir.

Jüri Üyeleri (Ünvan, Ad, Soyad):	İmza
Prof. Dr. Gürkan TUNA	……
Doç. Dr. Deniz Mertkan GEZGİN	……
Dr. Öğr. Üyesi Tarık YERLİKAYA	……
Dr. Öğr. Üyesi Murat Olcay ÖZCAN	……
Dr. Öğr. Üyesi Doğan ÜNAL	……

Tez Savunma Tarihi: 25/01/2021

Bu tezin Doktora tezi olarak gerekli şartları sağladığını onaylarım.

İmza

Prof. Dr. Gürkan TUNA
Tez Danışmanı ……

Trakya Üniversitesi Fen Bilimleri Enstitüsü onayı

Doç. Dr. H. R. Ferhat KARABULUT

Fen Bilimleri Enstitüsü Müdürü

T.Ü.FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ DOKTORA PROGRAMI
DOĞRULUK BEYANI

Trakya Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında, tüm verilerin bilimsel ve akademik kurallar çerçevesinde elde edildiğini, kullanılan verilerde tahrifat yapılmadığını, tezin akademik ve etik kurallara uygun olarak yazıldığını, kullanılan tüm literatür bilgilerinin bilimsel normlara uygun bir şekilde kaynak gösterilerek ilgili tezde yer aldığını ve bu tezin tamamı ya da herhangi bir bölümünün daha önceden Trakya Üniversitesi ya da farklı bir üniversitede tez çalışması olarak sunulmadığını beyan ederim.

.... / .... / ....

Ebru EFEOĞLU

İmza

Doktora Tezi

Mikrodalga Ölçüm Verilerinden Makine Öğrenmesi Teknikleri Kullanılarak Patlayıcı Madde Tespiti

T.Ü. Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

ÖZET

Tehlikeli sıvıların tespit edilmesi insan ve çevre sağlığının korunması açısından önemlidir. Çünkü bazı kimyasal sıvılar patlayıcı yapımında kullanılmakta ve bu patlayıcılarla teröristler saldırılar yapmaktadırlar. Terör saldırılarını önlemek için bu sıvıların diğer sıvılardan ayırt edilmesi gerekir. Bu nedenle araştırmacılar sıvı kontrolü yapan sistemler geliştirmek için çeşitli çalışmalar yürütmüşlerdir. Patlayıcı yapımında kullanılan sıvılar geliştirilen sıvı tarama sistemleri ile tespit edilmeye çalışılmıştır. Şuan kullanılmakta olan sıvı tarama sistemlerindeki yanlış alarm oranının yüksek olması ve bazı tehlikeli sıvıların tespit edilememesi araştırmacıları farklı yöntemler arayışına yöneltmiştir. Ayrıca operatöre bağlı sıvı tarama sistemlerinde operatörün dikkati kısa sürede dağılabilir, bu da sonuçların güvenilirliğini azaltabilir. Bu nedenle havalimanları, tren istasyonları, alışveriş merkezleri gibi insan nüfusunun kalabalık olduğu yerlerde bu tür saldırıları önlemek için sıvı kapağının açılması gerekmeyen ve yüksek doğrulukta sonuçlar veren sıvı tarama sistemleri kullanılmalıdır.

Bu tezde mikrodalga ve makine öğrenmesi tabanlı bir sıvı tanıma sistemi önerilmektedir. Önerilen sistem sıvı ve akışkanların mikrodalga frekans bandındaki elektromanyetik tepki ölçümlerine dayanmaktadır. Bu sistem hızlı, tahribatsız, operatöre bağımsız ve yüksek doğrulukla sonuç vermektedir. Ayrıca, bu sistem %70 ve daha fazla tehlikeli sıvı konsantrasyonuna sahip sıvıları tespit edebilmektedir. Çünkü çözeltilerde %70 ve üzeri bir sıvı konsantrasyonu da tehlike yaratabilmektedir. Önerilen sistem hem tehlikeli sıvıların tehlikesiz sıvılar arasından tespiti hem de bu tehlikeli sıvıların sulu

çözeltilerindeki tehlikeli sıvı konsantrasyonunu bulmak için kullanılmıştır. Her iki uygulamada en başarılı algoritmayı bulmak için kullanılan algoritmaların performans analizi yapılmıştır. Analizde yedi farklı algoritma kullanılmış ve bu algoritmalar arasından en iyi performansı K-EYK algoritması göstermiştir.

Yıl : 2021

Sayfa Sayısı : 134

Anahtar Kelimeler : Patlayıcı madde, Makine öğrenmesi, Mikrodalga

Doctoral Thesis
Explosive Detection Using Machine Learning Techniques From Microwave Measurement Data
Trakya University Institute of Natural Sciences
Department of Computer Engineering

ABSTRACT

Detecting hazardous liquids is important in terms of protecting human and environmental health. Because some chemical liquids are used to make explosives and terrorists attack with these explosives. In order to prevent terrorist attacks, these liquids must be distinguished from other liquids. Therefore, researchers have carried out various studies to develop systems that control liquids. With the developed liquid scanning systems, the liquids used in explosive production have been tried to determine. The high false alarm rate in liquid detection systems currently in use and the inability to detect some hazardous liquids led researchers to seek different methods. Also, the operator's attention can be distracted in a short time in operator-connected fluid scanning systems, which can reduce the reliability of the results. For this reason, liquid scanning systems that do not require the liquid cover to be opened and give high accuracy results should be used in order to prevent such attacks in places with crowded human populations such as airports, train stations, shopping malls.

In this thesis, a microwave and machine learning based liquid recognition system is proposed. The proposed system is based on electromagnetic response measurements of liquids and fluids in the microwave frequency band. This system is fast, non-destructive, operator independent and gives high accuracy. In addition, this system is able to detect liquids with a dangerous liquid concentration of 70% or more. Because a liquid concentration of 70% and above in solutions can also be dangerous. The proposed system has been used both to detect hazardous liquids among non-hazardous liquids and to find

the hazardous liquid concentration in aqueous solutions of these hazardous liquids. In order to find the most successful algorithm in both applications, performance analysis of the algorithms used has been made. Seven different algorithms have been used in the analysis and the K-EYK algorithm has showed the best performance among these algorithms.

Year : 2021

Number of Pages : 134

Keywords : Explosive, Machine learning, Microwave

TEŞEKKÜR

Tez çalışmam sırasında benimle bilgi birikimlerini paylaşan, beni yönlendiren ve desteklerini benden esirgemeyen çok değerli danışman hocam Prof. Dr. Gürkan TUNA'ya teşekkürlerimi sunarım.

Tezimin izleme komitesinde yer alan Doç. Dr. Deniz Mertkan GEZGİN ve Dr. Öğr. Üyesi Tarık YERLİKAYA'ya katkılarından dolayı teşekkür ederim.

Görüş ve önerileri ile tezin son şeklini almasını sağlayan tez jüri üyelerim Dr. Öğr. Üyesi Murat Olcay ÖZCAN'a ve Dr. Öğr. Üyesi Doğan ÜNAL'a teşekkür ederim.

Ayrıca öğrenim hayatımın her aşamasında sıkıntılarımı ve mutluluklarımı paylaşan aileme çok teşekkür ederim.

İÇİNDEKİLER

ÖZET……...iv
ABSTRACT……vi
TEŞEKKÜR……..……viii
İÇİNDEKİLER……....ix
SİMGELER DİZİNİ…….xiii
KISALTMALAR DİZİNİ……..xiv
ŞEKİLLER DİZİNİ…….....xv
ÇİZELGELER DİZİNİ…….....xvii
BÖLÜM 1…… 1
1 GİRİŞ 1
1.1 Patlayıcı Tespitinde Kullanılan Yöntemler 2
1.1.1 X Işını 2
1.1.1.1 X Işını İletim Radyografisi 2
1.1.1.2 X Işını Geri Saçılması 2
1.1.1.3 Çift Enerjili X Işını Sistemleri 3
1.1.1.4 X Işını Bilgisayarlı Tomografi 4
1.1.2 Nötron Teknolojileri 4
1.1.2.1 Termal Nötron Analizi (TNA) 5
1.1.2.2 Hızlı Nötron Analizi (HNA) 5
1.1.2.3 Darbeli Hızlı Nötron Analizi (DHNA) 6
1.1.2.4 Darbeli Hızlı Termal Nötron Analizi (DHTNA) 6
1.1.2.5 İlişkili Parçacık Tekniği (İPT) 6
1.1.2.6 Nötron Rezonans Radyografi (NRR) 6
1.1.3 Nükleer Dörtlü Rezonans (NDR) 6
1.1.4 Nükleer Rezonans Floresansı (NRF) 7
1.1.5 Nükleer Manyetik Rezonans(NMR) 7
1.1.6 Terahertz Spektroskopi ve Görüntüleme 7

1.1.7 Kızılötesi ve Ultraviyole 8
1.1.8 Raman Spektroskopisi 9
1.1.8.1 Tutarlı Raman 10
1.1.8.2 Yüzeyde Güçlendirilmiş Raman Saçılımı (YGRS) 10
BÖLÜM 2 13
2 ELEKTROMANYETİKTE TEMEL KAVRAMLAR 13
2.1 Elektromanyetik Dalgalar 13
2.1.1 Mikrodalgalar ve Mikrodalga Bantları 14
2.1.2 Elektromanyetik Malzemelerin Dielektrik Özellikleri 15
2.1.3 Elektromanyetik Dalganın Malzeme İçinde Yayılımı 17
2.2 Mikrodalga Ölçüm Yöntemleri 18
2.2.1 Serbest Ortam Ölçüm Yöntemi 19
2.2.2 Koaksiyel Prob Yöntemi 20
2.2.3 Dalga Kılavuzu Yöntemi 21
2.2.4 Rezonans Yöntemleri 21
2.3 Önerilen Ölçüm Sistemi ve Ölçüm Seti 22
2.3.1 Vektör Ağ Analizör 22
2.3.2 Saçılma Parametresi 23
2.3.3 Anten Tasarımı 25
2.3.3.1 Işıma Yaması 26
2.3.3.2 Dielektrik Ara Tabaka 27
2.3.3.3 Yer Düzlemi 27
2.3.3.4 Besleme Teknikleri 27
2.3.3.4.1 Koaksiyal Prob Besleme 27
2.3.3.4.2 Mikroserit Hat ile Besleme 28
2.3.3.5 Yama Yarıçap Hesabı 29
BÖLÜM 3 31
3 MAKİNE ÖĞRENMESİ 31
3.1 Makine Öğrenmesi Teknikleri 32
3.1.1 Denetimli Öğrenme 32
3.1.2 Denetimsiz Öğrenme 32
3.1.3 Yarı Denetimsiz Öğrenme 33
3.1.4 Pekiştirmeli Öğrenme 33

3.1.5 Uyum Sağlama Yoluyla Öğrenme 34
3.1.6 Öğrenmek İçin Öğrenme 34
3.2 Makine Öğrenmesi Süreç Aşamaları 34
3.2.1 Problemin Tanımı 35
3.2.2 Verilerin Analiz Edilmesi 35
3.2.3 Veri Hazırlığı 35
3.2.4 Modelin Oluşturulması 36
3.2.5 Modelin Değerlendirmesi 36
3.2.5.1 Dışarıda Tutma Yöntemi 37
3.2.5.2 K – Katlamalı Çapraz Doğrulama 37
3.2.5.2.1 Model Performans Değerlendirme Ölçütleri 38
3.2.5.2.1.1 Hata Matrisi 38
3.2.5.2.1.2 Kappa İstatistiği 40
3.2.5.2.1.3 Kök Ortalama Kare Hatası (KOKH) 41
3.2.5.2.1.4 Ortalama Mutlak Hata (OMH) 41
3.2.5.2.1.5 Bağıl Mutlak Hata (BMH) 42
3.2.5.2.1.6 Kök Bağıl Kare Hata (KBKH) 42
3.2.6 Modelin Kullanımı 42
3.3 Sınıflandırma ve Sınıflandırma Algoritmaları 43
3.3.1 Doğrusal Diskriminant Analizi (DDA) 43
3.3.2 Kuadratik Diskriminant Analizi (KDA) 44
3.3.3 Destek Vektör Makineleri (DVM) 45
3.3.4 Naive Bayes 47
3.3.5 Sıralı Minimal Optimizasyon (SMO) 48
3.3.6 En Yakın Komşu Algoritması (K-EYK) 50
3.3.7 K-Yıldız Algoritması 52
BÖLÜM 4 55
4 MİKRODALGA VERİLERİNİN SINIFLANDIRILMASI 54
4.1 Mikrodalga Verilerinden Tehlikeli Sıvı Tespiti 54
4.1.1 Tehlikeli Sıvı Tespitinde Algoritmaların Performansının Değerlendirilmesi 57
4.1.1.1 Naive Bayes Algoritması ile Tehlikeli Sıvı Tespiti 57
4.1.1.2 DDA Algoritması ile Tehlikeli Sıvı Tespiti 57
4.1.1.3 KDA Algoritması ile Tehlikeli Sıvı Tespiti 58

4.1.1.4 DVM Algoritması ile Tehlikeli Sıvı Tespiti 59
4.1.1.4.1 DVM Algoritmasında Farklı Çekirdek fonksiyon Kullanımı 59
4.1.1.5 SMO Algoritması ile Tehlikeli Sıvı Tespiti 63
4.1.1.6 K-EYK Algoritması ile Tehlikeli Sıvı Tespiti 64
4.1.1.6.1 K-EYK Algoritma Parametrelerinin Sınıflandırma Performansına Etkisi 65
4.1.1.7 K-Yıldız Algoritması ile Tehlikeli Sıvı Tespiti 75
4.2 Mikrodalga Verilerinden Sulu Çözeltilerdeki Tehlikeli Sıvı Konsantrasyonu Belirleme 77
4.2.1 Tehlikeli Sıvı Konsantrasyonu Belirlemede Algoritmaların Performansının Değerlendirilmesi 77
4.2.1.1 Naive Bayes Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti 78
4.2.1.2 DDA Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti 78
4.2.1.3 KDA Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti 79
4.2.1.4 DVM Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti 79
4.2.1.4.1 Tehlikeli Sıvı Konsantrasyonu Bulmada DVM Farklı Çekirdek Fonksiyon Kullanımı 80
4.2.1.5 SMO Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti 87
4.2.1.6 K-EYK Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti 89
4.2.1.6.1 K-EYK Parametrelerinin Alkol Konsantrsasyonu Bulmaya Etkisi 89
4.2.1.7 K-Yıldız Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti 98
BÖLÜM 5 102
5 SONUÇLAR VE TARTIŞMA 100
KAYNAKLAR 106
ÖZGEÇMİŞ 114
TEZ İLE İLGİLİ BİLİMSEL FAALİYETLER 115

SİMGELER DİZİNİ

a	Antenin yama yarıçapı
$\boldsymbol{\varepsilon}$	Elektrik geçirgenlik
$\boldsymbol{\varepsilon}^{"}$	Kayıp faktörü
$\boldsymbol{\varepsilon_r}$	Göreceli elektrik geçirgenlik
$\boldsymbol{f_r}$	Rezonans frekansı
h	Antenin alt tabaka yüksekliği
$\boldsymbol{\mu}$	Manyetik geçirgenlik
$\boldsymbol{\mu_r}$	Göreceli manyetik geçirgenlik
$\boldsymbol{\sigma}$	İletkenlik
$\boldsymbol{\delta}$	Kayıp açısı

KISALTMALAR DİZİNİ

BMH	Bağıl Mutlak Hata
DDA	Doğrusal Diskriminant Analizi
DHNA	Darbeli Hızlı Nötron Analizi
DHTNA	Darbeli Hızlı Termal Nötron Analizi
DVM	Destek Vektör Makineleri
HNA	Hızlı Nötron Analizi
İPT	İlişkili Parçacık Tekniği
KBKH	Kök Bağıl Kare Hata
KDA	Kuadratik Diskiriminant Analizi
K-EYK	K-En Yakın Komşu Algoritması
KOKH	Kök Ortalama Kare Hatası
MRG	Manyetik Rezonans Görüntüleme
NDR	Nükleer Dörtlü Rezonans
NMR	Nükleer Manyetik Rezonans
NRF	Nükleer Rezonans Floresansı
NRR	Nötron Rezonans Radyografi
OHM	Ortalama Kare Hata
OPO	Optik Parametrik Osilatör
RF	Radyo Frekansı
SMO	Sıralı Minimal Optimizasyon
TATP	Trisikloasetonperoksit
THZ-ZAS	Terahertz Zaman Alan Spektroskopi
TNA	Termal Nötron Analizi
YGRS	Yüzeyde Güçlendirilmiş Raman Saçılımı
ZTY	Zayıflatılmış Toplam Yansıma

ŞEKİLLER DİZİNİ

Şekil 2.1 Elektromanyetik dalga bileşenleri....13
Şekil 2.2 Işık tayfı....14
Şekil 2.3.Sanal dielektrik sabitinin vektör diyagramı....16
Şekil 2.4. Dalganın malzeme içerisinde yayılımı....18
Şekil 2.5. Serbest ortam ölçüm yöntemi....19
Şekil 2.6. Koaksiyel prob yöntemi ölçüm sistemi....20
Şekil 2.7. Dalga kılavuzu ölçüm sistemi ve dalga kılavuzları a)Dikdörtgen b) Dairesel c)H şekli....21
Şekil 2.8. Sıvı ölçümlerinde kullanılan ölçüm sistemi....22
Şekil 2.9. Vektör Ağ Analizörün şematik yapısı....23
Şekil 2.10. İki portlu bir devrenin s parametrelerinin belirlenmesi....23
Şekil 2.11. İki portlu bir doğrusal devrede gelen ve yansıyan dalgalar ile s- parametreleri....25
Şekil 2.12. Dairesel yama antenin fiziksel yapısı....26
Şekil 2.13. Antenin elektrik alan çizgileri....26
Şekil 2.14. Es eksenli hat ile besleme....28
Şekil 2.15. Mikroşerit hat ile besleme yöntemi....29
Şekil 2.16. Antende meydana gelen alan çizgilerinin dağılımı ve yüzey dalgaları....29
Şekil 2.17. Tasarlanan antenin geometrisi a) Antenin ön yüzü b) Antenin arka yüzü....30
Şekil 3.1. Makine öğrenmesi süreç aşamaları....34
Şekil 3.2. K – katlamalı çapraz doğrulama tekniği....37
Şekil 3.3. Doğrusal DVM'de destek vektörler.....45
Şekil 3.4. SMO Optimizasyonu (Bermejo vd., 2011)....48
Şekil 3.5. K-EYK algoritması kullanılarak sınıflandırılacak örneğe en yakın üç komşunun seçimi....50
Şekil 4.1. Ölçüm seti....54

Şekil 4.2. Alkol-su çözeltilerinin s-parametre ölçümleri a)Etanol b)Metanol c)1-Propanol d)İsopropanol 55
Şekil 4.3. Sıvıların s-parametresi ölçümleri 56
Şekil 4.4. Farklı fonksiyonlarla DVM algoritmasının tehlikeli sıvı bulmadaki doğruluk oranları 61
Şekil 4.5. Farklı fonksiyonlarla DVM algoritmasının ortalama mutlak hatası 62
Şekil 4.6. Farklı fonksiyonlarla DVM algoritmasının bağıl mutlak hatası 62
Şekil 4.7. Farklı fonksiyonlarla DVM algoritmasının kök ortalama kare hatası 63
Şekil 4.8. Farklı fonksiyonlarla DVM algoritmasının kök bağıl kare hatası 63
Şekil 4.9. Doğruluk oranı değişimi a)Öklid b)Chebyshev c)Manhattan d)Minkowski .. 70
Şekil 4.10. Ortalama mutlak hata a)Öklid b)Chebyshev c)Manhattan d)Minkowski 71
Şekil 4.11. Kök ortalama kare hata a)Öklid b)Chebyshev c)Manhattan d)Minkowski .. 72
Şekil 4.12. Bağıl mutlak kare hata a)Öklid b)Chebyshev c)Manhattan d)Minkowski ... 73
Şekil 4.13. Kök bağıl hata a)Öklid b)Chebyshev c)Manhattan d)Minkowski 74
Şekil 4.14. Algoritmaların tehlikeli sıvı bulmadaki doğruluk değerleri 75
Şekil 4.15. Naive Bayes ile tehlikeli sıvı konsantrasyonu bulma 78
Şekil 4.16. DDA ile tehlikeli sıvı konsantrasyonu bulma 78
Şekil 4.17. KDA ile tehlikeli sıvı konsantrasyonu bulma 79
Şekil 4.18. DVM ile tehlikeli sıvı konsantrasyonu bulma 79
Şekil 4.19. Doğrusal çekirdek fonksiyonu performans ölçütleri 80
Şekil 4.20. Polinomal çekirdek fonksiyonu performans ölçütleri 80
Şekil 4.21. Radyal Temel çekirdek fonksiyonu performans ölçütleri 81
Şekil 4.22. Sigmoid çekirdek fonksiyonu performans ölçütleri 81
Şekil 4.23. Farklı çekirdek fonksiyonlarının ortalama mutlak hatası 86
Şekil 4.24. Farklı çekirdek fonksiyonlarının bağıl mutlak hatası 86
Şekil 4.25. Farklı çekirdek fonksiyonlarının kök ortalama kare hatası 86
Şekil 4.26.Farklı çekirdek fonksiyonlarının kök bağıl kare hatası 87
Şekil 4.27. SMO ile tehlikeli sıvı konsantrasyonu bulma 87
Şekil 4.28. K-EYK ile tehlikeli sıvı konsantrasyonu bulma 89
Şekil 4.29. Chebyshev uzaklığında doğru ve yanlış tahmin edilen sıvı sayısındaki değişim 90
Şekil 4.30. Chebyshev uzaklığında doğruluk değerindeki değişim 90

Şekil 4.31. Öklid uzaklığında doğru ve yanlış tahmin edilen sıvı sayısındaki değişim..91
Şekil 4.32.Öklid uzaklığında doğruluk değerindeki değişim.....91
Şekil 4.33.Manhattan uzaklığında doğru ve yanlış tahmin edilen sıvı sayısındaki değişim 92
Şekil 4.34. Manhattan uzaklığında doğruluk değerindeki değişim.....92
Şekil 4.35. Minkowski uzaklığında doğru ve yanlış tahmin edilen sıvı sayısındaki değişim 93
Şekil 4.36.Minkowski uzaklığında doğruluk değerindeki değişim.....93
Şekil 4.37. Chebyshev uzaklığına ait hata değerleri a)Ortalama mutlak hata b)Kök ortalama kare hata c)Bağıl mutlak hata d)Kök bağıl kare hata.....94
Şekil 4.38. Öklid uzaklığına ait hata değerleri a)Ortalama mutlak hata b)Kök ortalama kare hata c)Bağıl mutlak hata d)Kök bağıl kare hata.....95
Şekil 4.39.Manhattan uzaklığına ait hata değerleri a)Ortalama mutlak hata b)Kök ortalama kare hata c)Bağıl mutlak hata d)Kök bağıl kare hata.....96
Şekil 4.40. Minkowski uzaklığına ait hata değerleri a)Ortalama mutlak hata b)Kök ortalama kare hata c)Bağıl mutlak hata d)Kök bağıl kare hata.....97
Şekil 4.41.K-Yıldız ile tehlikeli sıvı konsantrasyonu bulma 98

ÇİZELGELER DİZİNİ

Çizelge 3.1. Hata matrisi 38
Çizelge 3.2. Kappa değeri 41
Çizelge 3.3. DVM algoritmasında sıklıkla kullanılan çekirdek fonksiyonları 47
Çizelge 4.1. Ölçümlerde kullanılan sıvılar 55
Çizelge 4.2. Naive Bayes algoritmasının hata matrisi 57
Çizelge 4.3. DDA algoritmasının hata matrisi 58
Çizelge 4.4. KDA algoritmasının hata matrisi 58
Çizelge 4.5. DVM algoritmasının hata matrisi 59
Çizelge 4.6. DVM ile farklı çekirdek fonksiyonlarının hata matrisi 60
Çizelge 4.7. Farklı fonksiyon kullanımı ile DVM algoritmasının tehlikeli sıvı bulmadaki performans ölçütleri 61
Çizelge 4.8. SMO algoritmasının hata matrisi 64
Çizelge 4.9. K-EYK algoritmasının hata matrisi 64
Çizelge 4.10. Eğitimde Öklid uzaklığının hata matrisi 65
Çizelge 4.11. Eğitimde Chebyshev uzaklığının hata matrisi 66
Çizelge 4.12. Eğitimde Manhattan uzaklığının hata matrisi 66
Çizelge 4.13. Eğitimde Minkowski uzaklığının hata matrisi 67
Çizelge 4.14. Çapraz doğrulamada Öklid uzaklığının hata matrisi 67
Çizelge 4.15. Çapraz doğrulamada Chebyshev uzaklığının hata matrisi 68
Çizelge 4.16. Çapraz doğrulamada Manhattan uzaklığının hata matrisi 68
Çizelge 4.17. Çapraz doğrulamada Minkowski uzaklığının hata matrisi 69
Çizelge 4.18. K-Yıldız algoritmasının hata matrisi 75
Çizelge 4.19. Algoritmaların tehlikeli sıvı bulmadaki performans ölçütleri 76
Çizelge 4.20. Algoritmaların tehlikeli sıvı bulmadaki hata değerleri 77

Çizelge 4.21. Liner çekirdek DVM uygulaması ile tehlikeli sıvı konsantrasyonu doğru ve yanlış tahmin edilen sıvılar 82
Çizelge 4.22. Polinomal çekirdek DVM uygulaması ile tehlikeli sıvı konsantrasyonu doğru ve yanlış tahmin edilen sıvılar 83
Çizelge 4.23. Radyal temel çekirdek fonksiyonu DVM uygulaması ile tehlikeli sıvı konsantrasyonu doğru ve yanlış tahmin edilen sıvılar 84
Çizelge 4.24. Sigmoid çekirdek DVM uygulaması ile tehlikeli sıvı konsantrasyonu doğru ve yanlış tahmin edilen sıvılar..... 85
Çizelge 4.25. SMO algoritması ile alkol konsantrasyonu doğru ve yanlış tahmin edilen sıvılar..... 88
Çizelge 4.26. Algoritmaların tehlikeli sıvı konsantrasyonu bulmadaki hata değerleri ... 99

BÖLÜM 1

1 GİRİŞ

Tehlikeli kimyasal sıvıların etkileri sağlık, güvenlik, askeri ve sanayi gibi birçok alanda görülmektedir. Günlük yaşamda kolaylıkla bulunabilen bu sıvıların yanıcı sıvılar olması terör saldırında patlayıcı yapımında kullanılabilmesi düşüncesini oluşturmuş ve bu sıvılar sıklıkla terör eylemlerinde kullanılmaya başlanmıştır. Bu tehlikeli sıvılara hidrojen peroksit, aseton, alkol türleri örnek olarak verilebilir. Örneğin, yoğunlaştırılmış hidrojen peroksit metalle temasında şiddetli patlamalara sebep olmaktadır. 2005 yılının Temmuz ayında Londra'da düzenlenen saldırılarda kadınların sıklıkla kullandıkları oje çıkartıcı özelliğe sahip aseton kullanılarak 52 kişinin ölümüne neden olunmuştur. Genellikle bombalı saldırılarda, asit içerikli içeceklerin asetonla karıştırılarak kolaylıkla üretilebilen ve TATP (Trisikloasetonperoksit) adı verilen oldukça güçlü bir el yapımı patlayıcı madde kullanımı tercih edilmektedir. Bu patlayıcı darbelere, sürtünmeye ve bilhassa ısıya karşı dirençsizdir. Binlerce kişinin yaşadığı hava limanları, tren istasyonları, ulaşım noktaları, siyasi mitingler, alışveriş merkezleri, konserler ve diğer kültürel faaliyetler gibi yerlerde terör saldırıları için özellikle tercih edilmektedir. Günlük yaşamda kullanılan sıvılardan ayırt edilmesi oldukça zor olan bu sıvılar renkleri değiştirilerek ve günlük ihtiyaçlar için kullanılan şampuan, krem veya içecek şişelerine konularak havaalanı, tren istasyonları vb. yerlere alımı sağlanabilmektedir. Dolayısıyla bu merkezlerde güvenlik kontrol noktalarında sıvı kontrolü yapılmalı tehlikeli sıvılar tespit edilmelidir. Özellikle, 11 Eylül'de yaşanan hava saldırısı, dünya çapında farkındalığı artırmış ve güvenlik taramasında kullanılabilecek teknolojilerin geliştirilmesine neden olmuştur (Shea & Morgan, 2007). Tehlikeli nesnelerin tespitinde X ve Gama ışınlarının kullanımına dayalı temel yöntemler 1970'lerde geliştirilmiştir. Modern X ışını donanımı kullanılarak iyi çözünürlük ve nüfuz etme derinliğine sahip

görüntüler elde edilebilir. Geleneksel x-ışını tarama sistemleri, taranmış bir malzemeden geçen X ışını enerjisini ölçer (Kramers, 1923).Ancak, X ışını muayenesi, çeşitli patlayıcı ve plastik silah türlerinin yanı sıra sıvı patlayıcıları ve korumalı tehlikeli malzemeleri tespit edemeyebilir. Silahlar ve patlayıcılar, yüksek yoğunluklu diğer nesneler ve malzemeler kullanılarak da maskelenebilir. X ışını incelemesinin verimliliği, operatöre bağlıdır. Bununla birlikte, operatörün dikkati oldukça kısa bir süre sonra dağılabilir. Güvenlik düzeyini artırmak için, X ışını denetimi, şüpheli olmayan nesnelerin rastgele manuel denetimi de dahil olmak üzere bagajın manuel denetimi ile birleştirilir. Patlayıcıların tespiti için X ışını tekniklerinin uygulanması, patlayıcılar ve benzer atom numarasına sahip sivil malzemeler arasındaki yoğunluk farkına dayanmaktadır. En yaygın olarak kullanılan patlayıcıların çoğunun yoğunluğu 1,4 g / cm^{3}'ü aşmaktadır. Yoğunluk dağılımının eşzamanlı kaydı ve inceleme altındaki nesnedeki ortalama atom numarasının dağılımı, nispeten düşük seviyede yanlış alarmlarla gizli patlayıcıların tespitine izin verir. Bu nedenle, bilgi işleme için uygun donanım ve yazılım araçlarına sahip X ışını TV sistemleri, günümüzde patlayıcı tespiti için en hızlı, en uygun maliyetli araçlar olarak kabul edilmektedir. Son birkaç yılda bu tür sistemlerin geliştirilmesinde büyük ölçüde ilerleme sağlanmıştır. (Wilke, 2005) tarafından belirtildiği gibi, ana eğilim, bir operatörün katılımı olmadan patlayıcıları otomatik olarak algılayabilen sistemlerin geliştirilmesidir.

1.1 Patlayıcı Tespitinde Kullanılan Yöntemler

1.1.1 X Işını

1.1.1.1 X Işını İletim Radyografisi

Standart X ışını makineleri, genellikle TNT, dinamit ve plastik patlayıcıları harekete geçirmek amacıyla kullanılan fünyeleri, telleri ve silahları tespit eden sistemler olarak kullanılmaktadır. Bununla birlikte düşük enerjili X-ışını iletimi sistemi cam şişedeki sıvıları taramak için de kullanılmıştır. (Orachorn, Chankow, & Srisatit, 2017).

1.1.1.2 X Işını Geri Saçılması

Geri saçılan X ışını sistemleri, taranan nesneden kaynağa doğru geri saçılan X ışınlarından bir görüntü üretir. Malzemelerin ayrımı malzemelerin atom numarası ve

yoğunluklarına bağlıdır. Enerji dağıtıcı detektör teknolojisi kullanılarak X ışını saçılma modellerinden sıvı patlayıcıların tespiti (Kehres, Lyksborg, & Olsen, 2017) tarafından yapılmıştır.

1.1.1.3 Çift Enerjili X Işını Sistemleri

İletim tabanlı X ışını taraması (Madden, Mahdavieh, Smith, & Subramanian, 2008) ile tüm bagajın taranma süresi çok kaynaklı detektör geometrilerinin uygulanmasıyla azaltılmıştır (Harding, 2009; Skatter, Fritsch, & Schlomka, 2016). Çift enerjili radyografi yapan geleneksel tarayıcılarla, atom numarası ve yoğunluk elde edilebilir. Tehditlerin ve yasadışı maddelerin tanımlanması için kullanılabilir (Eilbert & Krug, 1993). Yüksek enerji seviyelerinde, emilen enerji malzemenin yoğunluğuna bağlıdır. Yoğunluk arttıkça nesne tarafından emilen enerji artar ve bu malzemelerin görüntüleri diğer malzemelere göre daha koyu renkli bir görüntü verir. Özellikle yoğunluğu fazla olan metal malzemeler ve silahların görüntüleri koyudur. Fakat yoğun bir malzemenin arkasında bulunan patlayıcı tespit edilememektedir. Bu sorunu çözebilmek için bagajdaki nesneleri iki enerji seviyesinde tarama yapılarak saptama yoluna gidilmiştir. Çoklu enerji görüntülerinin toplanması için, X ışını kaynağının giriş enerjisini değiştirmek ya da enerjiyi x-ışını sensöründe filtrelemek (Eilbert & Krug, 1992) ve farklı spektral özelliklere sahip birçok sensör kullanma gibi için çeşitli yöntemler bulunmaktadır. Ancak yine de, üst üste binen nesneler ve nesne kalınlığı nedeniyle oldukça yüksek sayıda yanlış sınıflandırma oranına sahiptirler. Güvenlik uygulamalarında tehdit malzemesi tanımlaması için daha doğru bir yaklaşım, malzemeyi kırılmış x-ışınları (O'Flynn vd., 2013), (Crespy, Duvauchelle, Kaftandjian, Soulez, & Ponard, 2010) kullanarak incelemektir. X ışını kırınımı teknikleri, bagaja nüfuz etmek için yeterli enerjiye sahip X ışınlarını kullanabilir (Harding vd., 2012). İlk olarak, incelenen hacim elemanında tutarlı bir şekilde dağılmış X ışınlarının girişiminden kaynaklanan kırınım modeli benzersizdir ve zayıflama kontrastından daha doğru bir parmak izi olarak yorumlanabilir. Makine öğreniminin X ışını kırınımına dayalı sınıflandırmaya uygulanması (Zhao, Wolter, & Greenberg, 2018) tarafından uygulanmıştır. Çift enerjili X ışını sistemleri, X ışını ışınlarının iki enerjide zayıflatılmasının karşılaştırılmasıyla malzeme ayrımı sağlar. Bununla birlikte, otomatik algılamanın güvenilirliği yetersiz olduğundan, sonuç yine de operatörün niteliğine

bağlıdır. Bu yöntem erken güvenlik sistemlerinde, silahların tespitinde kullanılmıştır. Havaalanlarındaki bazı ticari sistemler, bagaj çantalarındaki malzemelerin taranmasında bu tekniğe sahiptir (Eilbert & Krug, 1992). Bununla birlikte, uygulama, çok deneyimli operatörlerin bile plastik patlayıcıları tespit etmede zorluk yaşadıklarını göstermiştir (Ying, Naidu, & Crawford, 2006).

1.1.1.4 X Işını Bilgisayarlı Tomografi

X ışını algılama sistemlerinin daha da geliştirilmesi, bir nesnenin enine kesit görüntülerinin X ışını projeksiyonlarından sayısal olarak yeniden yapılandırıldığı daha da karmaşık bir X ışını tekniğidir. Bu kesit görüntüleri, üç boyutlu bir görüntü oluşturmak için birleştirilebilir. Bununla birlikte, el bagajı ve küçük boyutlu bagajların muayenesi için bilgisayarlı tomografinin başarılı bir şekilde uygulanmasına rağmen, şu ana kadar kargo konteynerlerinde patlayıcı maddelerin tespiti için uygun bu tür sistemler geliştirilmemiştir. X ışını teknolojisi, havacılık endüstrisinde yaygın olarak kullanılmaktadır. Bu yöntem nötron tabanlı yöntemlere karşılaştırıldığında daha ucuz ve kullanımının daha kolay olduğu görülmektedir. Ayrıca, insan ve bagaj içi çantaların taranmasında NMR'den daha güvenlidir. X ışını güvenlik cihazı bazı yanıcı, kolay patlayıcı ürünleri doğru bir şekilde tespit edemediğinden, Sun (2013) X ışını güvenlik sistemine gömülü olarak elektronik burun kokusu tanıma teknolojisi ile X ışını yönteminin kombinasyonundan oluşan iki aşamalı kontrol önermiştir. X ışını kırınımı tipik X ışını görüntüleme tekniklerine göre avantajları, (Wells & Bradley, 2012) ele alınmıştır. Katı ve sıvı patlayıcı tespiti için X ışını kırınımı kullanan görüntüleme cihazları mevcuttur. X-ışını kırınımıyla görüntüleme ilkeleri (Harding vd., 2012) tarafından özetlenmiştir. Son yıldaki birçok çalışma, tespit tekniklerini (Greenberg, Krishnamurthy, & Brady, 2013), analiz yöntemlerini (Crespy et vd., 2010) ve x-ışını geometrisinin (Greenberg & Brady, 2014; Dicken, Rogers, Evans, Rogers, & Chan, 2010) ve dedektör geometrisinin (B. Sun vd., 2010) optimizasyonunu birleştirerek tespit edilebilirliği iyileştirmek için yapılmıştır.

1.1.2 Nötron Teknolojileri

Beş ana nötron aktivasyon sorgulama tekniği vardır. Bunlar, termal nötron analizi (TNA), hızlı nötron analizi (HNA), darbeli hızlı termal nötron analizi, hızlı nötron elastik

saçılması ve nötron iletimi / hızlı nötron radyografisidir. 2014 yılında Whetstone ve Kearfott tarafından yapılan yeni bir incelemede bu sorgulama tekniklerinin her birinin arkasındaki temel ilkeler ile yöntemin avantaj ve dezavantajları açıklanmış her teknik için şu anda kullanılan farklı nötron kaynaklarına genel bir bakış sunulmuştur (Whetstone & Kearfott, 2014). Alternatif bir tespit yöntemi olarak, tespit için nötron saçılımını indüklemek için gama ışınlarının kullanılmasını önerilmiştir (McFee, Faust, & Pastor, 2013). Nötron tabanlı denetim sistemleri, ulusal güvenlik tehditlerinden, gümrük vergileri, sevkiyat kontrolü ve çevrenin korunmasına kadar farklı amaçlar için çok çeşitli maddeleri tespit edebilir. Bu sistemler genellikle nötronların sunulan çeşitli çekirdeklerle nükleer etkileşimleri sonucu meydana gelen karakteristik emisyonların tespiti üzerine kuruludur. Korumalı patlayıcıların tespitinde kullanılabilen sistemlerdir (Carasco vd., 2008). Nötron tabanlı teknikler, çeşitli senaryolarda ve operasyonel modlarda kullanılabilir. Araçlar gibi nesnelerin tam taramasını yapmak için bağımsız cihazlar olarak veya yüksek enerjili X ışını radyografisi gibi başka bir denetim sistemi tarafından gösterilen alarmları doğrulamak için kullanılabilirler (Obhodas vd., 2010). Nanosaniye nötron analizine dayalı tehlikeli madde dedektörü ile patlayıcı ve yanıcı sıvıların tespiti için teknik deneysel olarak gösterilmiştir (Kalinin vd., 2008).

1.1.2.1 Termal Nötron Analizi (TNA)

TNA, gizli sıvı patlayıcı tehditleri tespit etmek için etkili bir yöntem sağlar (Shaw vd., 2005). Bu tekniğin temeli, nitrojen içinde yakalanan termal nötronlardan gama ışınlarının tespit edilmesidir. Tespit emisyonu, çok yüksek enerjiye sahiptir, bu da diğer pek çok bozucu materyalin varlığında nitrojeni ayırt etmeyi mümkün kılar. Diğer olası reaksiyonlar olsa da, nitrojen üzerinde termal nötronların kullanılması hızlandırıcı gerektirmez. Termal nötronlar, enerji ayarı için bir moderatör uygulayarak bir radyoizotop veya küçük bir hızlandırıcı ile üretilebilir. Bu nedenle, termal nötronlara dayanan sistemler nispeten küçük boyuttadır ve daha az koruma gerektirir.

1.1.2.2 Hızlı Nötron Analizi (HNA)

Hızlı Nötron Analizi, hızlı nötronların, çoğunlukla esnek olmayan nötron saçılması yoluyla, ilgili unsurlarla, özellikle de patlayıcıların karbon, nitrojen ve oksijeni ile etkileşimine dayanır. Giden gama ışınlarının bir aralığını tespit edip ölçerek, temel

oranlarını hesaplamak mümkündür. HNA genellikle TNA' dan çok daha karmaşık ve pahalıdır.

1.1.2.3 Darbeli Hızlı Nötron Analizi (DHNA)

Darbeli işlemler, arka plan radyasyonunun nötron etkileşimlerinden etkisini azaltmada yararlı olabilecek zamanlama bilgilerinin kullanımına izin verir. Darbeli işlemler, çok kısa hızlı nötron darbelerine sahiptirler. Bu teknik, gerekli özelliklere sahip bir nötron ışını üretmek için, hızlı elektronikler ve son derece hassas ve ayırt edici detektörler ile birlikte oldukça büyük kurulumlar gerektirmektedir.

1.1.2.4 Darbeli Hızlı Termal Nötron Analizi (DHTNA)

DHTNA, nötron tabanlı patlayıcı tespit sisteminin başka bir formunu temsil eder. Kurulumu, arada mikrosaniye duraklamalarla hızlı nötronların darbelerini kullanır ve hem hızlı hem de termal nötron reaksiyonlarından kaynaklanan gama ışınlarını ölçebilir.

1.1.2.5 İlişkili Parçacık Tekniği (İPT)

İlişkili parçacık görüntüleme tekniği, birincil nötronun, bir elektronik nötron üretecinde döteryum-trityum füzyon reaksiyonu yoluyla üretilen ilişkili alfa parçacıkları tarafından "etiketlenmesini" içerir. Bu yöntem, alfa parçacıklarının algılama süresini ölçerek ve yalnızca "etiketli" nötronlarla çakışan gama ışınlarını malzeme içeriği tanımlamasını kabul ederek ışık süresi tekniğini kullanabilir.

1.1.2.6 Nötron Rezonans Radyografi (NRR)

Yolcu bavullarında patlayıcı ve uyuşturucuların tespiti için Hızlı Nötron Rezonans Radyografisi (NRR) kullanılabilir. NRR yöntemi ile farklı nötron enerjilerinde alınan hızlı nötron radyografik görüntüler, hidrojen, karbon, nitrojen, oksijen ve diğer elementlerin karakteristik temel özelliklerine göre haritalanmasında kullanılır. Böylece, patlayıcılar ve ilaçlar, karakteristik temel bileşimleriyle tespit edilebilir ve tanımlanabilir.

1.1.3 Nükleer Dörtlü Rezonans (NDR)

Patlayıcıların tespiti için kullanılan temel radyo frekansı tekniği Nükleer Dörtlü Rezonans (NDR)'tır (Itozaki, 2009). NDR' nin temel prensibi, tıp alanında kullanılan Manyetik Rezonans Görüntülemeyle (MRG) aynıdır. Nükleer spin tarafından ışınlanan

ve emilen Radyo Frekansı (RF) dalgası, çekirdek önceki sabit durum yönüne döndüğünde daha sonra yeniden yayılır. Bu emisyonun frekansları farklı malzemelere özeldir. Bu nedenle patlayıcı veya diğer malzemelerin niteliği ve miktarı belirlenebilir. NDR teknolojisi, düşük maliyet, insandan bağımsız çalışma ve herhangi bir iyonlaştırıcı radyasyonun olmaması gibi birçok avantaj sergiler, ancak yalnızca kristal yapılı patlayıcıları tespit edebilir ve arka plan radyo parazitine duyarlıdır. Son zamanlarda (Espy vd., 2010), sıvı patlayıcıları tespit edebilen Ultra Düşük Alan Manyetik Rezonans Görüntüleme tekniği tanıtılmıştır, ancak tıbbi ve güvenlik uygulamaları arasında teknolojik bir geçiş hala gereklidir.

1.1.4 Nükleer Rezonans Floresansı (NRF)

NRF tekniği patlayıcı maddenin atomlarının enerji seviyelerinin uyarılmasına dayanmaktadır (Bertozzi & Ledoux, 2005). Bu, belirli izotoplara özgü frekanslarda yeniden saçılmaya neden olur. Bu yöntem çok yenidir ve avantajlarını ve dezavantajlarını tartışmak erken olur. Bununla birlikte, başarısının esasen tespit sistemlerinin geliştirilmesindeki ilerlemeye bağlı olduğu unutulmamalıdır. Yani, yüksek çözünürlüklü (2 - 10 MeV aralığındaki dar floresan hatlara göre) dedektörler gereklidir. Şu anda, bu yalnızca kararlı geniş spektrumlu gama ışını kaynaklarının ve yüksek çözünürlüklü pahalı soğutma dedektörlerinin mevcut olduğu laboratuvar düzeyinde mümkündür.

1.1.5 Nükleer Manyetik Rezonans(NMR)

Gradišek ve Apih tarafından NMR tabanlı sıvı patlayıcı dedektörü önerilmiştir (Gradišek & Apih, 2010). Düşük alanlı manyetik rezonans görüntüleme kullanılarak patlayıcı tespiti (Krylatykh vd., 2016) ve NMR kullanılarak sıvı patlayıcıların tespiti ve sınıflandırılması yapılmıştır (Gudmundson, Jakobsson, Poplett, & Smith, 2009).

1.1.6 Terahertz Spektroskopi ve Görüntüleme

Terahertz (THz) spektroskopisi yönteminde spektral bölge genellikle 0,5 ile10 THz frekansları veya 15 ila 300 cm^{-1} dalga sayıları olarak tanımlanır. THz spektroskopisinin ümit verici bir özelliği, gizli nesneleri tespit etmek için bir nimet olan metalik olmayan öğelere nüfuz etme ve algılama yeteneğidir. Çeşitli geleneksel ve ev yapımı patlayıcıların spektral imzalarının elde edilmesinin yanı sıra hem spektroskopi

hem de görüntüleme şemaları için sinyal işleme tekniklerinin geliştirilmesi konusunda halen çok sayıda araştırma yapılmaktadır. Tespit limiti gibi nicel analitik ölçütleri içeren birkaç THz tespit kağıdı vardır. Yöntemin seçiciliği, özellikle THz spektral imzaları ve bunların örnek tipi veya matris ile varyasyonlarını içerdiği durumlar tartışılmıştır. THz spektroskopisi için yaygın bir teknik, bir pompa-prob yöntemi olan Zaman Alan Spektroskopisidir (THz-ZAS). THz elektrik alanı belirli bir süre boyunca kaydedilebilir ve Fourier bir frekans spektrumuna dönüştürülebilir. Geleneksel moleküler patlayıcılar RDX, HMX, PETN ve benzer moleküller (Trofimov, Varentsova, & Chen, 2010; Sleiman vd., 2014) dahil olmak üzere patlayıcıların ve ilgili malzemelerin spektral imzaları üzerinde THz-ZAS aracılığıyla çok sayıda araştırma yapılmıştır. Benzer şekilde, patlayıcı karışımların ve plastik bileşimlerin spektral imzaları da incelenmiştir (Barber vd., 2010; Gavenda & Křesálek, 2013; Maestrojuan vd., 2011). Ek olarak, ev yapımı patlayıcıların ve ilgili malzemelerin spektral imzaları analiz edilmiştir (Witko, Buchanan, & Korter, 2011; Witko & Korter, 2012). Operatörün numuneden fiziksel olarak ayrıldığı THz TDS kullanılarak uzaklaşma tespiti de araştırılmıştır (Trofimov, Varentsova, Szustakowski, & Palka, 2012; Walczakowski, Palka, Szustakowski, Czerwinski, & Sypek, 2013). Patlayıcı nesneleri hem tespit etmek hem de tanımlamak için araştırmalar da birkaç grup tarafından gerçekleştirilmiştir. RDX, PETN ve RDX / PETN karışımlarının kimyasal haritalaması için THz-ZAS kullanmıştır (Sleiman vd., 2014). (Startsev & Elezzabi, 2013) çeşitli patlayıcıları frekans taraması için ayarlanabilir bir optik parametrik osilatör (OPO) kullanılmıştır. THz-ZAS ve OPO tabanlı bir sistemle patlayıcıların THz iletim spektrumlarını karşılaştırılmıştır (Palka vd., 2012). THz-ZAS ve OPO tabanlı bir sistemle patlayıcıların THz iletim spektrumları ve patlayıcıların tespiti için spektroskopik tekniklerdeki son gelişmeler incelenmiştir (Zhang vd., 2018). THz zaman alan spektroskopisi kullanılarak yanıcı ve patlayıcı sıvıların tespiti yapılmıştır (Tan vd., 2017; Tan vd., 2018).

1.1.7 Kızılötesi ve Ultraviyole

Kızılötesi soğurma / yansıtma / zayıflatılmış toplam yansıma (ZTY) spektroskopileri, titreşim spektrumunun ölçümü yoluyla patlayıcı tanımlama ve algılama için güçlü yöntemlerdir. ZTY, geleneksel olarak transmisyon kızıl ötesi ölçümlerinde yer alan numune hazırlığından kaçınır. Saf malzemeler için kızılötesi nüfuz etme derinliği bir

mikrometre düzeyinde olduğundan, ZTY prizması ile temas halinde yerleştirilebilirlerse çok az miktarda katı veya sıvı ölçülebilir. Kızılötesi duyarlı odak düzlemi dizisi detektörü ile birlikte 30 saniyede eser miktarda patlayıcıyı tespit etme ve belirleme yeteneğine sahiptir (Bingham, Lucey, Akagi, Hinrichs, & Knobbe, 2014; Wagner vd., 2015). Deneysel uygulama daha basit, daha küçük ve daha az maliyetlidir. Bu avantajlar ultraviyole ışınının patlayıcı tespiti ve tanımlaması uygulamalarında kullanıma teşvik etmiştir. Ultraviyole, 200-500 nm aralığında aktif aydınlatma altında diferansiyel hiperspektral görüntüleme (Dubroca, Guetard, & Hummel, 2012; Dubroca, Moyant, & Hummel, 2013) kullanılmıştır. TNT için 100 ng tespit edilebilmiştir (Dubroca, Brown, & Hummel, 2014). Nitro ve peroksit organik patlayıcıların son derece hassas tespiti için yeni bir ters çevrilebilir floresan probu önerilmiştir (George vd., 2019). Etanol-su karışımlarında moleküler etkileşimin yakın kızılötesi spektroskopik çalışması yapılmıştır (Dong vd., 2019).

1.1.8 Raman Spektroskopisi

Raman spektroskopisi, son incelemelerde (Fountain, Christesen, Moon, Guicheteau, & Emmons, 2014; Lopez-Lopez & Garcia-Ruiz, 2014) açıklandığı gibi, güçlü tanımlama yetenekleri ve çok yüksek seçiciliği nedeniyle en yoğun kullanılan ve aktif olarak çalışılan patlayıcı algılama yöntemlerinden biridir. Raman'ın ölçtüğü moleküler titreşim spektrumu, farklı moleküler yapılar için farklı olan çok yüksek bilgi içeriğine (çok sayıda keskin spektral özelliğe) sahiptir. Spektrumlardaki bu varyasyonlar, patlayıcıların, kimyasalların ve diğer metal olmayan malzemelerin kesin tanımlanmasına izin verir. Raman ölçümleri lazer uyarımı, saçılan ışığın verimli bir şekilde toplanması, uyarma ışığının reddedilmesi, spektral dağılım ve algılama gerektirir. Bilinmeyen kimyasalları tanımlayabilen kapsamlı kitaplıklarla donatılmış, ticari olarak temin edilebilen el tipi Raman spektrometreleri günümüzde kullanılmaktadır. Ultraviyole ışığı retinaya odaklanmadan önce gözde emildiğinde, ultraviyole darbeli lazerlerin göze zarar vermeyen koşullar altında çalışan potansiyel patlayıcı algılama platformları olduğu gösterilmiştir. Bu da önemli bir husustur (Almaviva vd., 2014; Glimtoft vd., 2014). Floresan rekabeti için diğer potansiyel çözümler, daha uzun dalga boyu uyarımına geçmek veya nanosaniye altı zaman kapıları kullanmaktır (Åkeson vd., 2011). Çünkü Raman yalnızca uyarım darbesi sırasında yayılır ve floresan tipik olarak birkaç

nanosaniye üzerinde gerçekleşmektedir. Alternatif olarak, flüoresan girişimini ortadan kaldırmak için kaydırılmış uyarma farkı yöntemleri (hafifçe kaydırılmış uyarma dalga boyları ile elde edilen iki Raman spektrumunun farkını alarak) kullanılabilir (Shreve, Cherepy, & Mathies, 1992). Havacılık güvenliğinde patlayıcı tanımlama için Raman spektroskopisindeki gelişmeler incelenmiştir (Santillán, Brown, & Jalenak, 2007). Havacılık güvenliği için el yapımı patlayıcılarda kullanılan metanol, etanol, izoapil alkol çeşitli oranlarda suyla ikili karışımları Raman spektroskopisi kullanılarak incelenmiştir (Patsaeva, Dolenko, Burikov, & Yuzhakov, 2014). Su-etanol-metanol karışımlarında metanolün tespiti için spektroskopik ölçümü yapılmıştır (Vašková & Tomeček, 2018).

1.1.8.1 Tutarlı Raman

Tutarlı Raman yöntemleri, daha karmaşık lazer uyarma kaynakları pahasına, spontan Raman'dan 104 kat daha güçlü seviyelerde Raman imzalarının uyarılmasına izin verir (Dogariu, 2013; Portnov, Bar, & Rosenwaks, 2010). DNT ve diğer kimyasalların spektral tanımlanması ve taranmış görüntülenmesi için femtosaniye süper sürekliliğin darbe şekillendirmesini kullanan Tutarlı anti-Stokes Raman spektroskopi (TARS) kullanılmıştır (Bremer, Wrzesinski, Butcher, Lozovoy, & Dantus, 2011). Patlayıcılarda istenen özelliklerin seçici olarak uyarılması için darbe şekillendirmeli Femtosaniye TARS da gösterilmiştir (David Steven Moore, McGrane, Greenfield, & Scharff, 2012; David S Moore vd., 2011). Femtosaniye, spektral çözünürlük elde etmek için bir darbe şekillendirici kullanarak Raman saçılmasını uyarmış, 10 metreye kadar patlayıcı tanımlama için titreşimli görüntüleme göstermiştir (Bremer & Dantus, 2013). Nanosaniye TARS ayrıca patlayıcı tespiti ve tanımlamasını da göstermiştir (Portnov vd., 2010).

1.1.8.2 Yüzeyde Güçlendirilmiş Raman Saçılımı (YGRS)

YGRS, izli patlayıcıların (Lopez-Lopez & Garcia-Ruiz, 2014) tek katman düzeyine kadar miktarlarda tespiti ve tanımlanması için Raman spektroskopisinden yararlanmanın bir yolu olarak geniş çapta araştırılmıştır. Ultra-trace analizi için plazmonik mühendisliği de içeren YGRS yönteminin detayları Baker ve Moore (Baker & Moore, 2005) tarafından gözden geçirilmiştir. YGRS 'in ilgi çekici yanlarından biri, metal nano yapının boyutunu ve şeklini değiştirerek geliştirme özelliklerini ayarlama yeteneğidir. YGRS 'in seçiciliği, ilk önce farklı fonksiyonel gruplara sahip molekülleri metal yüzeylerde emilerek ayarlanabilir. YGRS aktif substratlar birçok şekilde gelir.

Sıklıkla, bir dielektrik substrat üzerinde gümüş veya altın nanopartiküllerdir. Ek olarak, çözelti içindeki bakır (Hamad, Podagatlapalli, Mohiddon, & Rao, 2015), gümüş (Podagatlapalli, Hamad, Mohiddon, & Rao, 2014) veya altının (Jamil, Izake, Sivanesan, & Fredericks, 2015) lazerle etkileşimiyle, koloidal, YGRS aktif bir çözelti oluşturmuş ve ANTA, FOX-7 ve TNT' yi tespit etmek için kullanılmıştır. Son zamanlarda pek çok araştırma, YGRS 'i bir patlayıcı tespit yöntemi olarak kullanmanın pratik yönlerine odaklanmıştır. Birkaç araştırmacı tarafından patlayıcı tespiti için farklı substratlar kullanmayı denenmiş ve RDX (Jamil vd., 2015; Almaviva vd., 2012), PETN (Botti, Cantarini, Almaviva, Puiu, & Rufoloni, 2014) ve TNT (Holthoff, Stratis-Cullum, & Hankus, 2011) 'u saptamak için uygun bir substrat önerilmiştir. Raza ve arkadaşları (Raza & Saha, 2014), filtre kağıdı üzerinde büyütülmüş gümüş nano partiküllerden oluşan alternatif bir ucuz YGRS test şeridi geliştirmiştir. Test şeritleri TNT'yi başarıyla tespit etmiştir. Geleneksel Raman spektroskopisinde olduğu gibi, moleküler YGRS parmak izi, bir patlayıcı tespit cihazında YGRS kullanımı için pratik bir değerlendirme olan kirletici maddeler tarafından gizlenebilir. Araştırmacılar, bir poli (stiren-ko-akrilik asit) çekirdek ve manyetit kabuktan oluşan karmaşık bir hibrit mikro küre kullanarak, altın nanopartiküller (Hatab, Eres, Hatzinger, & Gu, 2010) ve 2 pM TNT kullanarak kirli yeraltı suyunda 0.15 mg / L RDX tespit edebildiler. , TNT seçiciliğini artırmak için altın nanoküre ve lignin ile kaplanmıştır. (Mahmoud & Zourob, 2013). Bu alandaki diğer araştırmalar, yeraltı sularında ve pH'ta yaygın olarak bulunan iyonların, YGRS 'in TNT' yi tespit etme etkinliği üzerindeki etkisine odaklanmıştır (Xu & Meng, 2012; C. Zhang, Wang, Han, & Pang, 2014). Malzeme karışımlarının spektral imzalarını YGRS kullanarak ayırmak ve başarılı bir şekilde tanımlamak zor olabilir. Olası bir çözüm sunulmuştur (Zachhuber, Carrillo-Carrión, Simonet Suau, & Lendl, 2012), DNT - 2,4 -- DNT ve 2,6 -- DNT'nin iki izomerini ayırmak için mikro sıvı kromatografi kullanılmıştır. Mikroakışkan bir kanalda hazırlanmış, gümüş ve altınla kaplı silikon bazlı nano yapılı yüzeyler geliştirmiştir (Talian & Huebner, 2013), DNB ve 2,4 -- DNT'yi başarıyla ayrılmış ve karakterize edilmiştir. Seçiciliği artırmak için solüsyonda sisteamin içeren koloidal bir altın nanopartikül solüsyonu kullanmıştır (Jamil vd., 2015). Sisteamin ve TNT bir Meisenheimer kompleksi oluşturmuş ve bu daha sonra kendiliğinden altın nanopartiküller üzerine monte edilmiş ve YGRS tarafından tespit edilmiştir. Sisteaminin, tercihen DNT ve pikrik asit yerine TNT ile kompleksi oluşturduğu bulunmuştur. YGRS,

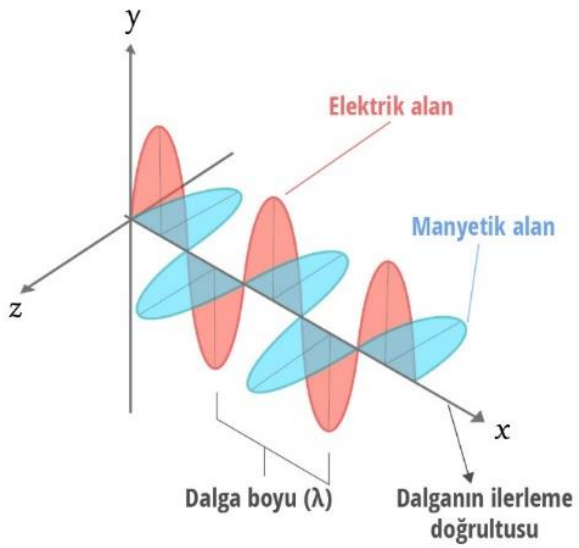
patlayıcıların tespitinde en üst düzeye çıkmak için diğer teknolojilerle birleştirilme denenmiştir (Büttner vd., 2013), TNT'ye benzer kimyasal yapılara sahip olan ancak losyonlarda ve kokularda bulunan misk keton ve misk ksileni TNT'den ayırmak için YGRS i yüzeyde geliştirilmiş IR emilimi (SEIRA) ile birleştirmiştir. Hem Raman'ı hem de IR'yi zenginleştiren altın kaplı silikon nanopillerden oluşan bir plasmonik substrat geliştirmişlerdir. (Holthoff vd., 2011).Yüzey iyileştirilmiş Raman saçılımı ile patlayıcı algılama sistemi kullanılmıştır (Gillibert, Huang, Zhang, Fu, & de la Chapelle, 2018). Sıvı patlayıcı tespiti için uzamsal ofset Raman spektroskopisinin performansı incelenmiş (Loeffen vd., 2016), amonyum nitratın tespiti için Raman spektroskopi yöntemi kullanılmıştır (Diaz & Hahn, 2020). Patlayıcı tespit metodolojilerinin gözden geçirilmesi ve derin UV rezonansı Raman'ın ortaya çıkışı (Gares, Hufziger, Bykov, & Asher, 2016) sağlanmıştır. Nanosaniye zaman kapılı Raman spektroskopisi kullanılarak yarı saydam plastik şişelerde gizlenmiş sıvı patlayıcıların ve tehlikeli kimyasalların tespiti yapılmıştır (Gulati, Gambhir, Kumar, & Gambhir, 2019). Uzak Hiperspektral Raman Görüntüleme ve Rasgele Kararlı Orman Sınıflandırması patlayıcıların hızlı ve uzaktan tanımlanması için güçlü bir ikili olmuştur (Gasser, Göschl, Ofner, & Lendl, 2019).

BÖLÜM 2

2 ELEKTROMANYETİKTE TEMEL KAVRAMLAR

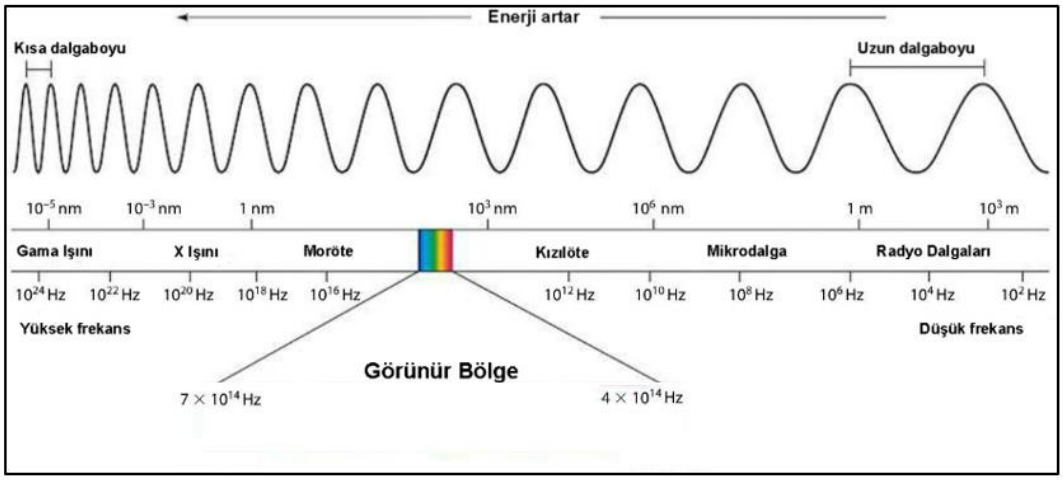
2.1 Elektromanyetik Dalgalar

Elektromanyetik dalgalar aynı fazda bulunan, titreşim doğrultuları birbirlerine ve ilerleme doğrultusuna dik olan elektrik ve manyetik alandan oluşur. Elektromanyetik dalganın bileşenleri Şekil 2.1'de verilmiştir. Elektromanyetik dalganın oluşabilmesi için ivmeli hareket eden bir yüke ihtiyaç vardır. Çünkü elektrik ve manyetik alanda meydana gelen değişiklikler elektrik alan ve manyetik alanın oluşmasını sağlar. Elektrik alandaki değişime bir manyetik alan, manyetik alandaki değişime de bir elektrik alan mutlaka eşlik eder. Yani hareketsiz veya düzgün doğrusal hareket eden yük elektromanyetik dalga oluşturamaz.



Şekil 2.1 Elektromanyetik dalga bileşenleri.

Elektromanyetik dalgalar boşlukta ışık hızıyla yayılırlar. Hızları farklı ortamlara geçtiklerinde değişir. Yüksüz olmaları nedeniyle elektrik ve manyetik alandan herhangi bir şekilde etkilenmezler. Bu dalgalar soğurulabilen dalgalardır ve dalgaların frekans aralıklarına göre farklı isimlendirilme yapılabilir. Bu isimlendirmeye ışık tayfı adı verilir ve Şekil 2.2'de gösterilmiştir.



Şekil 2.2 Işık tayfı.

2.1.1 Mikrodalgalar ve Mikrodalga Bantları

1 GHz in üzerinde bir frekansa sahip olmaları nedeniyle mikrodalgaların dalga boyları kısa olur. Bu dalgalara mikrodalga denmesinin sebebi de budur. Dalga boyunun kısa olması birçok uygulama alanında avantaj sağlar. Bu avantajlar, göreceli olarak küçük antenler ve düşük kuvvetli vericiler kullanabilme olarak sıralanabilir. Ayrıca yüksek frekanslı dalgalar olması nedeniyle iletişim kanalları için oldukça yüksek bant aralığında ve büyük miktarlarda veri iletimi yapabilirler. Mikrodalgalar frekans bantlarına göre gruplara ayrılır (Clark, McKenna, & Nanzer, 2015).

L frekans bandı, 1 GHz ile 2 GHz'dir. Bu bant aralığındaki dalgalar genellikle askeri uygulamalarda, cep telefonlarında kullanılır.

S frekans bandı, 2 GHz ile 4 GHz'dir. Genellikle bu bant aralığındaki dalgalar kablosuz ağlarda kullanılırlar.

C frekans bandı, 4 GHz ile 8 GHz arasında, değişen dalgalardır. Hava olaylarından etkilenmemeleri bu dalgaların uzun menzilli telsiz iletişiminde kullanılma olanağı sağlar.

X frekans bandı, 8 GHz ile 12 GHz arası frekans aralığında, değişen dalga boyuna sahiptir. X bant mikrodalgaların kullanım alanları uydu haberleşmesi, geniş bant iletişimi ve radarlardır.

Ku frekans bandında olan mikrodalgaların frekans aralığı 12 GHZ ile 18 GHz arasında değişir. Enerji değişiklikleri ölçümlerinde, rüzgarın hızının ve yönünün belirlenmesinde kullanılırlar.

K frekans bandı, 18 GHz ile 26,5 GHz frekans aralığında değişen dalgalardır. Bu dalgaların bir kısmı kızılötesi alanında bulunduğu için hem radar ve uydu alanlarında hem de astronomik gözlemleri için kullanılırlar.

Ka frekans bandındaki dalgaların frekans bant aralığı 26,5- 40 GHz. Bu dalgalar uydu iletişimi için elverişli dalgalardır.

V frekans bandındaki dalgaların frekans bant aralığı 40-75 ve w frekans bandındaki dalgaların frekans bant aralığı 75-110Ghz'dir.

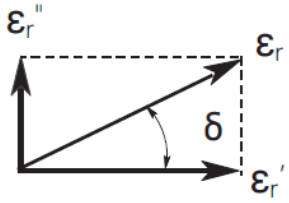
2.1.2 Elektromanyetik Malzemelerin Dielektrik Özellikleri

Mikrodalga frekans bandında kullanılan malzemelerin özelliklerinin belirlenmesi önemli bir konudur. Malzemelerin davranışını değerlendirebilmek için elektromanyetik teoriye dayanan bazı kavramların bilinmesi gerekir. Bu nedenle bu bölümde dielektrikler ve elektromanyetik alanda dielektriklerin davranışları hakkında bilgi verilmiştir. Bu çalışmada sıvılar dielektrik malzeme olarak ele alınmıştır. Malzemeyi belirleyen özellikler elektriksel geçirgenlik (ε), manyetik geçirgenlik (μ) ve iletkenlik (σ) şeklinde sıralanabilir. SI (Uluslararası Birimler Sistemi) göre bu parametrelerin birimleri sırasıyla şöyledir. Elektriksel geçirgenlik parametresinin birimi Farad/metre (F/m), Manyetik geçirgenlik Henry/metre (H/m) ve iletkenlik birimi de Siemens/metre (S/m) dir. Elektromanyetik dalganın bir malzeme içerisinde ilerleyişi bu parametrelere bağlıdır. Elektrik ve manyetik alanlar malzemelerle enerji depolama ve enerji dağıtımı olmak üzere iki türlü etkileşime girer. Enerji depolama alanı ve malzeme arasındaki enerji alışverişinin kayıpsız kısmını tanımlar. Enerji dağılımı, elektromanyetik enerji malzeme tarafından emildiğinde meydana gelir. Elektriksel geçirgenlik (ε), bir malzemenin üzerine

uygulanan elektrik alanla etkileşimini, Manyetik geçirgenlik (μ), bir malzemenin üzerine uygulanan manyetik alanla etkileşimini açıklar. Dielektrik yani diğer bir adıyla yalıtkan malzemeler kendilerine uygulanan elektrik alanı enerji olarak depolayabilen malzemelerdir. Elektriksel geçirgenliği farklı olan malzemeler elektrik sinyallerine farklı tepkiler verirler (Rammah, Zakaria, Ruslan, & Isa, 2015). Bu nedenle elektriksel geçirgenlik malzeme karakterizasyonunda kullanılan bir parametredir (Rocha vd., 2013). Yalıtkan bir malzemenin dielektrik özellikleri kompleks dielektrik sabiti Denklem (2.1)' deki gibi tanımlanır ve elektrik alanı şeklinde bir malzemede depolanabilen enerjinin miktarını belirtirken gerçel kısım (ε') ile kayıp faktörü olarak adlandırılan ve malzeme içinde ısı şeklinde yayılan enerjinin ölçüsü olarak gösterilen sanal kısımdan ($\varepsilon^{"}$) oluşur.

$$\varepsilon = \varepsilon' - j\varepsilon^{"} \tag{2.1}$$

Burada j=-1'dir. Gerçel ve sanal kısımların 90 derecelik bileşenlerinin vektörel toplamından oluşan sanal dielektrik sabitinin vektör diyagramı Şekil 2.3'te verilmiştir.



Şekil 2.3.Sanal dielektrik sabitinin vektör diyagramı.

Şekildeki vektörlerin toplamı gerçel eksenle yaptığı açıya kayıp açısı denir ve δ ile gösterilir. Dielektrikteki enerji kaybı oranı ayrıca kayıp tanjantı olarak ta adlandırılır. Kayıp tanjant bağıl kayıp faktörünün dielektrik sabitine oranı olarak Denklem (2.2)'de gösterilmiştir.

$$tan\delta = \frac{\varepsilon^{"}}{\varepsilon'} \tag{2.2}$$

Manyetik geçirgenlik, elektrik geçirgenlik gibi enerji depolamayı ifade eden sanal (μ') ve enerji dağılımını ifade eden gerçek kısımlardan ($\mu^{"}$) oluşan kompleks bir yapıdadır ve Denklem (2.3) ile ifade edilir.

$$\mu = \mu' - j\mu^{"} \tag{2.3}$$

Mikrodalga elektroniklerinde genellikle boyutsuz miktarlar göreceli elektrik geçirgenlik (ε_r) ve göreceli manyetik geçirgenlik (μ_r) kullanılır ve Denklem (2.4) ve Denklem (2.5) ile hesaplanır.

$$\varepsilon_r = \frac{\varepsilon}{\varepsilon_0} = \frac{\varepsilon' - j\varepsilon''}{\varepsilon_0} = \varepsilon_r' - j\varepsilon_r'' \tag{2.4}$$

$$\mu_r = \frac{\mu}{\mu_0} = \frac{\mu' - j\mu''}{\mu_0} = \mu_r' - j\mu_r'' \tag{2.5}$$

Burada ε_0 =8,854.10^{12} F/m değerine sahiptir ve boşluktaki elektriksel geçirgenliği ifade ederken, μ_0 = 4π.10^{-7}H/m değeri ise boşluktaki manyetik geçirgenlik değeridir. (Chen, Ong, Neo, Varadan, & Varadan, 2004). Elektrik ve manyetik geçirgenlik sabit değildir. Frekansa bağlı olarak değişir. Bir dielektrik malzemenin geçirgenliğinin değişimine düşük frekanslarda iyon iletkenliği, mikrodalga frekans bandında dipolar gevşeme, kızıl ötesi bölgesinde ise atomik ve elektronik polarizasyonlar neden olmaktadır. Malzeme özelliklerini belirleyen diğer bir özellik ise iletkenlik (σ) değeridir. Bu değer bir malzemenin elektrik akımı iletme yeteneğini ifade eder. Elektriksel geçirgenlik ile ilişkisi Denklem (2.6) ve Denklem (2.7) ile gösterilmiştir.

$$\varepsilon'' = \frac{\sigma}{\omega} \tag{2.6}$$

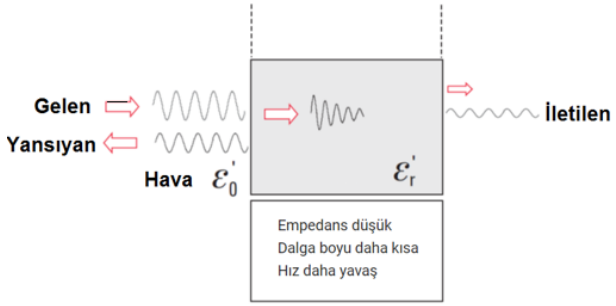
$$\varepsilon_r = \varepsilon_r' - j\frac{\sigma}{\varepsilon_0 \omega} \tag{2.7}$$

Burada, ω açısal frekanstır.

2.1.3 Elektromanyetik Dalganın Malzeme İçinde Yayılımı

Elektromanyetik dalga, boşlukta ışık hızında (c = 3 x 108 m / s) yayılırlar. Çeşitli dalga boylarında elektromanyetik dalgalar vardır. Bir sinyalin dalga boyu, frekansı f (λ = c / f) ile ters orantılıdır, yani frekans azaldıkça dalga boyu artar. Bir malzemenin elektrik ve manyetik geçirgenliği dalganın malzeme içinde yayılımını etkiler. Dalganın malzeme içerisinde yayılımı sırasında enerjinin bir kısmı malzemeden geçip iletilirken bir kısmı da geri yansır (Tereshchenko, Buesink, & Leferink, 2011). Enerji korunumu yasası gereğince yansıma, iletim ve emilme enerjilerinin toplamı dalganın ilk baştaki enerjisinin

toplamına eşittir. Şekil 2.4'te görüldüğü gibi malzemenin içine giren dalganın, dalga hızı, ışık hızından daha yavaş, dalga boyu da daha kısa olur.



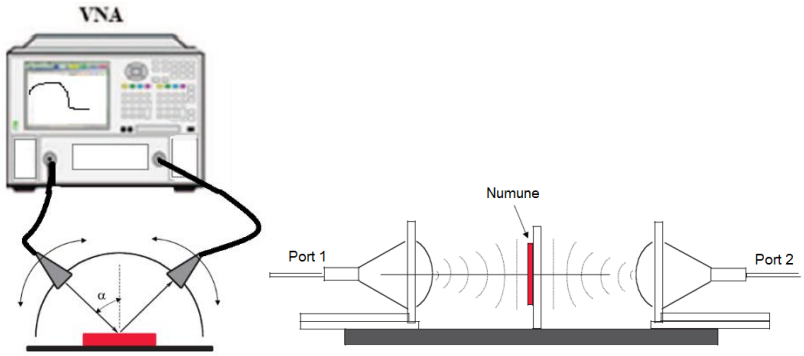
Şekil 2.4. Dalganın malzeme içerisinde yayılımı.

2.2 Mikrodalga Ölçüm Yöntemleri

Malzeme karakterizasyonda kullanılan birçok mikrodalga ölçüm yöntemi vardır. Her yöntem kendine göre avantaj ve dezavantajlara sahiptir. İhtiyaca uygun olarak en verimli yöntem belirlenmeli ve o yöntem kullanılmalıdır. Ölçüm yöntemleri rezonant ve rezonant olmayan ölçüm yöntemleri olarak ikiye ayrılır. Rezonat ölçüm yönteminde tek bir frekans kullanılırken, rezonant olmayan ölçüm yönteminde ise geniş frekans bantı kullanılır (Khan & Ali, 2012; Chen vd., 2004). İhtiyaca uygun olan ölçüm yöntemini bulmak için hangi yöntemin ne tür malzeme ölçümünde kullanıldığını (katı, sıvı, gaz), hangi parametreleri ölçebildiğini (S_{11}, S_{12}) ve malzemenin hangi parametrelerin (ε_r, μ_r) hesaplanabildiğinin bilinmesi gerekir. Bunların yanı sıra kullanılacak ölçüm yönteminin ucuz olması ve pratik olması kullanımının kolay olması da önemlidir (Al-Mously, 2012). Serbest uzay yöntemi, dalga kılavuzu, rezonant kavite yöntemlerinde ε_r,μ_r farklı hesaplama yöntemleri ile hesaplanabilirken koaksiyel prob yönteminde sadece ε_r hesaplanabilmekte ve sadece S_{11} ölçümü yapılabilmektedir. Malzeme ölçümleri dalga kılavuzu yöntemi tahribatlıdır ve numune hazırlama işlemi zordur. Dalga kılavuzu yönteminde sadece katı malzemelerin ölçümleri yapılabilmektedir. Serbest uzay yönteminde ölçülecek malzemenin büyük olması gerekmektedir (Khan & Ali, 2012; Tereshchenko vd., 2011). Sistem kalibrasyonu tüm ölçüm yöntemlerinde yapılmalıdır. Kalibrasyon için bilinen bir malzeme kullanılabilir (Santos, Dias, Aguiar, Borges Jr, & Borges, 2009).

2.2.1 Serbest Ortam Ölçüm Yöntemi

Serbest alan yönteminde, dielektrik karakteristikleri ölçmek için büyük, düz ve her iki tarafın düzgün yüzlü homojen katı malzemelerden örnekleri kullanılır. Tipik bir serbest ortam iletim tekniğinde, numune bir verici ve bir alıcı anten arasına yerleştirilir ve sinyalin zayıflaması ve faz kayması ölçülür, buradan numunenin dielektrik özellikleri belirlenebilir. Numuneyle fiziksel teması olmadan yansıma ve iletim katsayılarını elde edilebilir, İnce yassı malzemeler için daha uygun bir ölçüm yöntemidir. Elektrik ve manyetik geçirgenlik değerleri hesaplanabilir. Geniş ve yüksek frekans bandında ölçüm yapılabilir. Numune boyutunun büyük olması gerekir küçük numune ölçümlerini yüksek doğrulukla yapılması zordur. Temassızdır ve yüksek sıcaklıklarda test edilecek malzemelere uygulanabilir. Şekil 2.5 'te ölçüm sisteminin şematik gösterimi mevcuttur. Sistem bir Vektör ağ Analizöre, bir alıcı ve bir verici anten olmak üzere iki antenden oluşmaktadır. Ölçüm yapılacak malzeme numune tutucuya yerleştirilir. Bir antenden gönderilen sinyal diğer anten aracılığıyla alınır.



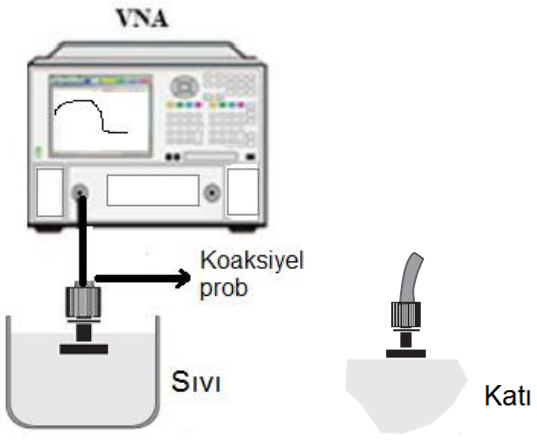
Şekil 2.5. Serbest ortam ölçüm yöntemi.

Bu ölçüm yönteminde s-parametre ölçümü için numuneye bir ön hazırlık aşamasında bulunmadan ölçüm yapılabilir. Bu yöntem ile yapılan ölçümlerde bazı sorunlar yaşanmaktadır. Ölçüm doğruluğunu etkileyen bu sorunlar şöyle sıralanabilir. Birinci sorun ölçülecek numunenin kenarlarındaki kırınımlar antenler arası çoklu yansımalara sebebiyet vermektedir. Bu da ölçüm için istemeyen bir olaydır. İkinci sorun ise numune ile antenler arasında hava boşluğunun bulunmasıdır (Haddadi, Wang, Benzaim, Glay, & Lasri, 2008; Yin, Chao, & Xu, 2005). Üçüncü sorun da antenlerin seçimi, antenlerin doğru açılarla yerleştirebilmesi ve antenin odak noktası hesabının zor olmasıdır. Ayrıca numune

tutucunun tasarımına ve numune geometrisine dikkat edilmeli numune yeri iyi seçilmelidir (Li, Haigh, Soutis, Gibson, & Sloan, 2017).

2.2.2 Koaksiyel Prob Yöntemi

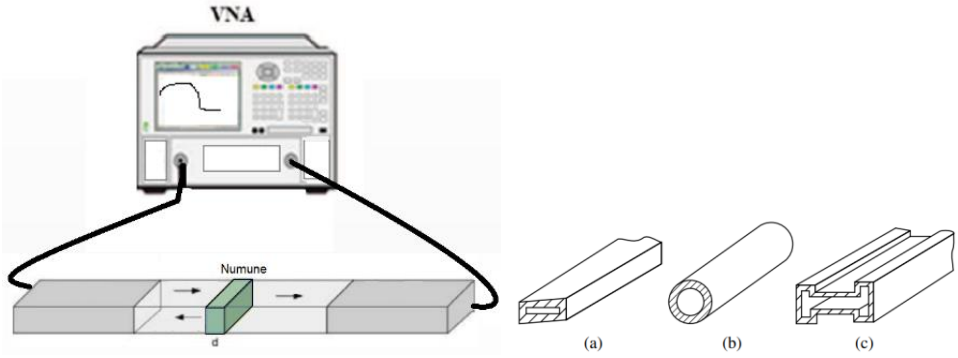
Koaksiyel prob yöntemi, yüksek frekanslarda kayıplı malzemeleri ölçmek için en sık kullanılan tekniklerden biridir. Genellikle koaksiyel prob veya açık uçlu bir koaksiyel hat yöntemi olarak bilinir. Karmaşık yansıma katsayısını ölçen ağ analizörleriyle kullanılır (Athey, Stuchly, & Stuchly, 1982). 0.5 GHz ila 110 GHz arasındaki geniş frekans aralığında dielektrik ölçümleri yapılabilir. Sadece S_{11} parametre ölçümü yapılıp elektrik geçirgenlik değeri hesaplanabilir. Geniş frekans aralığında ölçüm olanağı sağlar. Temassız ölçüm mümkün değildir. Ölçüm sıvı malzemelerde probun sıvı içerisine batırılması ile katı malzemelerde de probun numunenin yüzeyine değdirilmesi ile gerçekleştirilir. Koaksiyel prob yönteminde katı malzeme ölçümlerinde malzeme ile prob arasında hava boşluğunun bulunmamasına ve numunesi alınan malzemenin yüzeyinin düz olmasına özen gösterilmesi ölçüm doğruluğu açısından önemlidir. Uygun olmayan temas yüzeyleri ölçüm hatalarına neden olur. Bu nedenle ölçüm yapılmadan önce numunenin ön hazırlığa tabi tutulması temas yüzeyinin mümkün olduğunca düzleştirilmesi gerekir. Koaksiyel prob yöntemi kullanan tipik bir ölçüm sistemi bir ağ analizörü ve bir koaksiyel prob, prob standı ve kablodan oluşur sistemin şematik gösterimi Şekil 2.6'da verilmiştir.



Şekil 2.6. Koaksiyel prob yöntemi ölçüm sistemi.

2.2.3 Dalga Kılavuzu Yöntemi

Ölçümler için hem yansıma (S_{11}) hem de iletim katsayıları (S_{21}) kullanılır ve elektrik ve manyetik geçirgenlik değerleri hesaplanabilir. Koaksiyel probdan daha yüksek doğruluk ve daha fazla hassasiyete sahiptir, ancak nispeten koaksiyel probdan daha dar bir frekans aralığına sahiptir. Parçalı frekans bandında ölçüm yapılabilir. Tahribatsız ölçüm gerçekleştirilemez. Sadece katı malzeme ölçümleri yapılabilir. İletim hattı yöntemlerinden biri olan bu yöntemde malzemeyi kapalı bir iletim hattının bir kısmının içine yerleştirilir. Dalga kılavuzları farklı şekildeki kesitlere (dairesel, eliptik veya dikdörtgen) sahip olabilir, fakat en çok tercih edilen dikdörtgen kesitlilerdir ve Şekil 2.7'de gösterilmiştir. Ölçülecek numuneler dalga kılavuzları içerisine yerleştirilerek ölçüm yapılacağı için malzemelere dalga kılavuzu şekli verilmelidir.



Şekil 2.7. Dalga kılavuzu ölçüm sistemi ve dalga kılavuzları a) Dikdörtgen b) Dairesel c) H şekli.

İmalatının kolay olması, paslanmaya karşı dayanıklı olması nedeniyle genellikle dalga kılavuzları metalden üretilirler. Dalga kılavuzu yönteminde sıvı ölçümlerinde numunenin çevresinde sızıntı sorunu yaşanabilir. Katı numune ölçümlerinde de ölçülecek malzemeye ait numune boyutunda da sorun yaşanabilir. Çünkü ölçüm yapılabilmesi için numunenin hattın numune koymak için ayrılan yeri ile aynı boyutlarında olması gerekir.

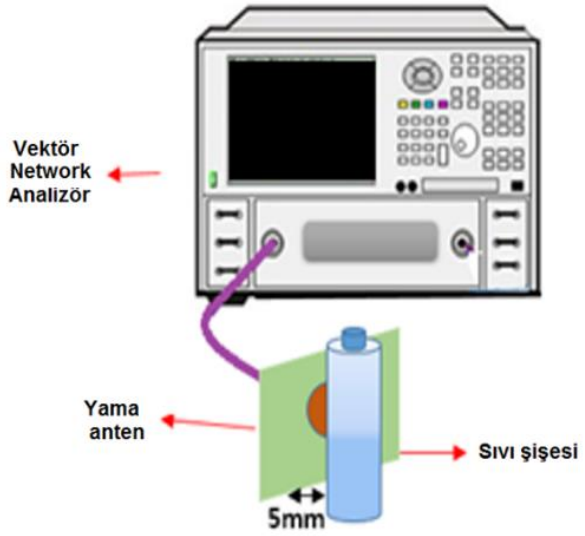
2.2.4 Rezonans Yöntemleri

Rezonant yöntemler genellikle rezonans olmayan yöntemlerden daha yüksek doğruluklara ve hassasiyetlere sahiptir, çünkü tek bir frekansta veya ayrı bir frekans setinde çalışırlar. Rezonans yöntemleri genellikle rezonatör yöntemleri ve rezonans

pertürbasyon yöntemleri olarak sınıflandırılabilir (Saeed, Shafique, Byrne, & Hunter, 2012). Rezonatör yöntemleri, ölçülecek materyalin bir rezonatör olarak işlev gördüğü ve sadece çok düşük kayıplı numunelere uygulanabilen yöntemlerdir. Bu amaçla kullanılan farklı rezonatör tipleri ayrıca dielektrik, koaksiyel boşluk ve bölünmüş rezonatörler olarak sınıflandırılabilir (Chen vd., 2004). Rezonant pertürbasyon yöntemleri, numunenin tepkide bir bozulmaya neden olan bir rezonant yapıya sokulduğu yöntemlerdir. Pertürbasyon, rezonant frekansında bir kayma ve numunenin dielektrik özelliklerinin türetilebileceği rezonatörün yüksüz kalite faktörünün azalması ile sonuçlanır. Rezonans pertürbasyon tekniği düşük ve orta kayıplı numuneler için çok uygundur.

2.3 Önerilen Ölçüm Sistemi ve Ölçüm Seti

Ölçüm düzeneği bir vektör ağ analizör ve dairesel yama antenden oluşmaktadır. Ölçüm sisteminin şematik gösterimi Şekil 2.8'de gösterilmiştir.

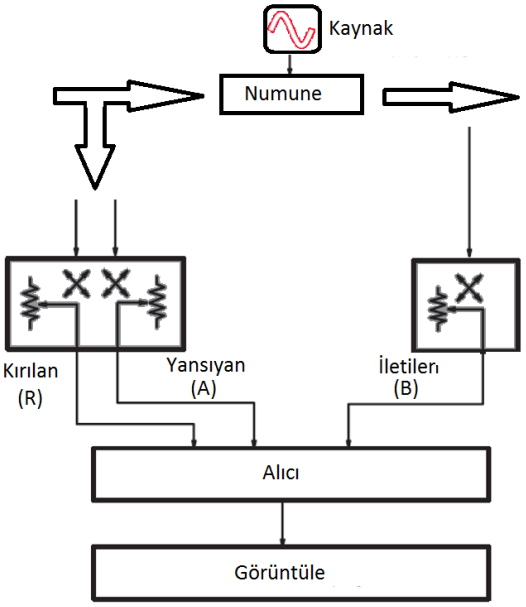


Şekil 2.8. Sıvı ölçümlerinde kullanılan ölçüm sistemi.

2.3.1 Vektör Ağ Analizör

Bir malzemeden yansımanın ve / veya iletimin bilgisinin ölçülmesi, malzemenin karakterize edilebilmesi için bilgi sağlar. Bir vektör ağ analizörü bir sinyal kaynağı, bir alıcı ve bir ekrandan oluşur. Şekil 2.9'da şematik gösterimi yapılmıştır. Kaynak, test edilen malzemeye tek bir frekansta bir sinyal gönderir. Alıcı, malzemeden yansıtılan ve iletilen sinyalleri tespit etmek için bu frekansa ayarlanır. Ölçülen yanıt, o frekanstaki

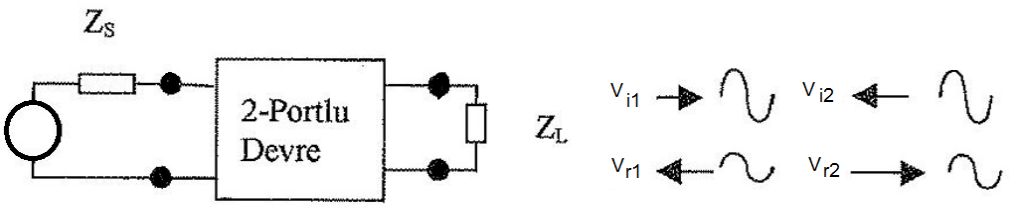
büyüklük ve faz verilerini üretir. Daha sonra kaynak bir sonraki frekansa geçirilir ve yansıma ve iletim ölçüm tepkisini frekansın bir fonksiyonu olarak görüntülemek için ölçüm tekrarlanır.



Şekil 2.9. Vektör Ağ Analizörün şematik yapısı.

2.3.2 Saçılma Parametresi

S parametreleri mikrodalga devrelerinde kullanımı elverişli olduğundan sıklıkla kullanılır. S parametrelerinde esas olan gelen ve giden dalga değerleridir. Özellikle dalga kulavuzlarında akım ve gerilim ölçümlerinin yapılamaması nedeniyle s parametreleri kullanılması gereklidir. Şekil 2.10' da iki portlu bir devre görülmektedir. S parametreleri hesabı için devre bir iletim hattına yerleştirilip bu hattın karakteristik empedansına eşit bir yük uygulaması yapılabilir.



Şekil 2.10. İki portlu bir devrenin s parametrelerinin belirlenmesi.

Kaynaktan bir işaret gönderilir ve bu işaret ile devre uyarılır. Yanıt işareti ise yansıyan işaret ile devre çıkışından alınan transfer işaretinden oluşmaktadır. Gelen ve giden işaretlerin (Şekil) gerilim değerlerini Denklem (2.8) ve Denklem (2.9) vasıtasıyla hesaplamak mümkünkür.

$$V_{r1} = S_{11}V_{i1} + S_{12}V_{i2} \tag{2.8}$$

$$V_{r2} = S_{21}V_{i1} + S_{22}V_{i2} \tag{2.9}$$

Burada V_{i1},V_{i2} devreye uygulanan gerilim değerlerini V_{r1}, V_{r2} ise devreden yansıyan gerilim değerlerini temsil etmektedir. Uygulamalarda yüksek frekanslarda işaretin dalga boyu nedeniyle gerilim ölçümleri zordur. Bunun yerine gerilim daha kullanışlıdır. Devreye giren ve yansıya gerilim karakteristik empedansın (Z_0) karekökü ile normalize edilmesi durumunda, gücün karekökü şu şekilde elde edilir Denklem (2.10) ve Denklem (2.11);

$$b_n = \frac{V_m}{\sqrt{Z_0}} \tag{2.10}$$

$$a_n = \frac{V_{in}}{\sqrt{Z_0}} \tag{2.11}$$

Güç ifadesini kullanarak iki portlu devre yeni ifade Denklem (2.12) ve Denklem (2.13)'te verildiği gibi olur.

$$b_1 = S_{11}a_1 + S_{12}a_2 \tag{2.12}$$

$$b_2 = S_{21}a_1 + S_{22}a_2 \tag{2.13}$$

Doğrusal iki portlu bir devrenin s-parametreleri Şekil 2.11'de gösterilmiştir. Hesaplanmak istenen parametreye göre portlara empedans bağlaması yapılarak parametre hesabı yapılabilir. Örneğin, geri yansıyan işaretin olmaması durumunda yani a_2 =0 iken denklemde verilen S_{11} ve S_{21} hesaplanabilir. a_2 nin sıfır olması için ikinci porta iletim empedansına eşit bir empedans bağlanması gerekir ki empedansın üzerine uygulanan işaret hemen harcansın ve geriye sinyal yansıması olmasın. Bu durumda (a_2=0 iken) Denklem (2.14) ve Denklem (2.15);

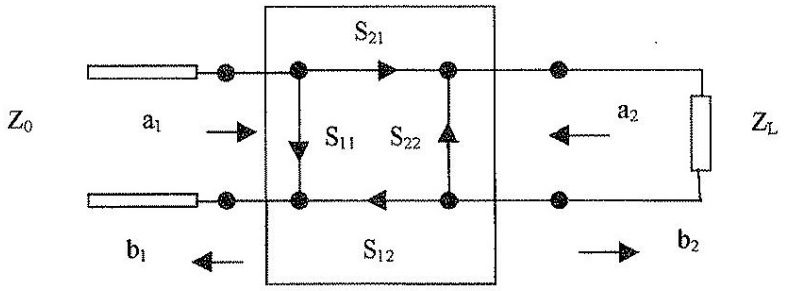
$$S_{11} = \frac{b_1}{a_1} \tag{2.14}$$

$$S_{21} = \frac{b_2}{a_1} \tag{2.15}$$

a_1=0 olması durumunda ise S_{22} ve S_{12} parametreleri Denklem (2.16) ve Denklem (2.17) de verildiği gibi olur.

$$S_{22} = \frac{b_2}{a_2} \tag{2.16}$$

$$S_{12} = \frac{b_1}{a_2} \tag{2.17}$$

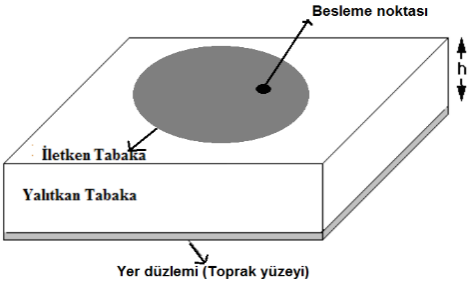


Şekil 2.11. İki portlu bir doğrusal devrede gelen ve yansıyan dalgalar ile s-parametreleri

S parametreleri büyüklük ve faz kısmından oluşan kompleks sayılardır ve giren dalgaya bağlı büyüklük ve faz değerleri değişir. Ayrıca yük ve kaynak empedansı değişimi ve frekans değişimi de s parametrelerini etkilemektedir.

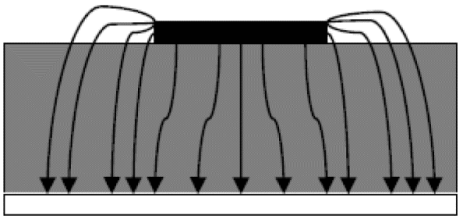
2.3.3 Anten Tasarımı

Yama antenler bir yer düzlemi üzerinde yer alan dielektrik tabakanın üzerindeki farklı geometrilere sahip iletken tabakanın yerleştirilmesi ile oluşturulurlar. Anten yamaları kare, daire, elips, vb. şekiller olabilir. Tasarlanan dairesel yama antenin fiziksel yapısı Şekil 2.12' de gösterilmektedir.



Şekil 2.12. Dairesel yama antenin fiziksel yapısı.

Yama antende ışıma; antenin iletken tabakası ile toprak tabakası arasında oluşur. Antenin elektrik alan dağılımı ise aşağıdaki örnekte verildiği şekilde gerçekleşir. Yama antenin iletken tabakası ile yer düzlemi (toprak düzlemi) arasında anten ışıma yapar. Antenin elektrik alan dağılımını gösterimi Şekil 2.13' de gösterilmiştir.



Şekil 2.13. Antenin elektrik alan çizgileri.

Sekil 2.13'ten de görüldüğü gibi, en fazla ışıma iletken tabakanın kenar alanlarında oluşmaktadır.

2.3.3.1 Işıma Yaması

Işıma yaması, elektromanyetik dalgaların emilimi ya da ışıma yapabilmesini sağlayan iletken ve belirli bir şekle sahiptir. Bu yama dielektrik bir tabaka üzerine konumlandırılır ve genelde bakır veya gümüş gibi malzemeler kullanılır. Yama boyutları ve şekli kullanım amacına frekansa bağlı olarak farklılık gösterebilir. Tez kapsamında daire şekilli bir yama anten tasarlanmıştır. Daire yama tercih edilmesinin nedeni dairesel yamanın dikdörtgen ve diğer şekillerdeki yama tiplerinde bulunmayan simetrik ışıma karakteristiğine sahip olma özelliğidir. Dairesel yama seçimine etken olan bir başka faktör de ölçümlerde dairesel bir şişenin kullanılıyor olmasıdır.

2.3.3.2 Dielektrik Ara Tabaka

Anten ışıma yaması ile yer düzleminin bulunduğu alt taraf arasında kalan malzemedir. Bu tabakadaki malzeme seçimi yapılırken göreceli geçirgenliğinin 2,2 ila 12 arasında değişen malzemeler tercih edilebilir. Bu seçimin yapılmasında dielektrik sabitinin yanı sıra maliyet ve kalınlık faktörleri de etkilidir. Bu tabakanın kalınlığı, frekans bant genişliği ile doğru orantılıdır. Bu nedenle anten verimliliği arttırmak için düşük dielektrik sabitine sahip kalın bir tabaka tercih edilmelidir. Tasarlanan antendeki dielektrik tabakanın dielektrik sabiti 4,4'tür. Bu tabaka piyasada rahatlıkla bulunabilen ucuz FR-4 malzemeden yapılmıştır.

2.3.3.3 Yer Düzlemi

Yer düzleminde kullanılan iletken malzeme ışıma yamasında kullanılan malzeme ile benzer özelliktedir. Yer düzleminin boyutlarının artması anten performansı / verimliliğini arttırabilir. Bu nedenle maksimum performans elde edilen boyutlar kullanılmalıdır.

2.3.3.4 Besleme Teknikleri

Anten tasarımında en sık kullanılan besleme yöntemleri mikroşerit besleme yöntemi ve koaksiyel prob besleme yöntemidir. Tez kapsamında tasarlanıp üretilen antende koaksiyel prob besleme yöntemi kullanılmıştır.

2.3.3.4.1 Koaksiyal Prob Besleme

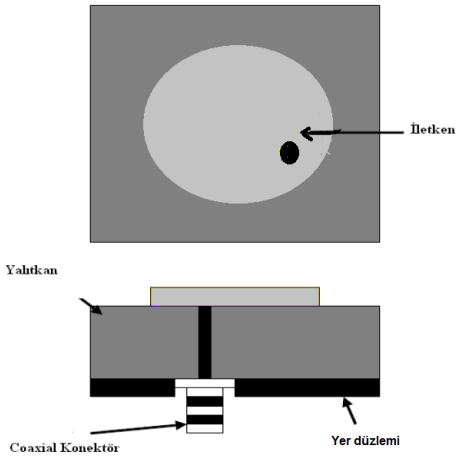
Koaksiyel Probun iç kısımda bulunan iletkeni antenin ışıma yamasına dış kısımda bulunan iletkeni antenin yer düzlemine bağlanır. Koaksiyel prob besleme yöntemi ince tabaka kullanılan antenler için daha kullanışlıdır ve imalatı kolay olmaktadır. Yapay ışıma karakteristiği düşük ve diğer besleme yöntemlerine göre daha dar bir bant genişliğine sahiptir. Düşük parazit ışıma nedeniyle çok fazla tercih edilen besleme yöntemidir.

Bu besleme yöntemi üç grupta toplanabilir. Bunlar;

- Besleme noktası simetriyi bozmayacak şekilde iletken tabakanın üzerinde bir noktada bulunur. Bu tür besleme yöntemi merkezi besleme yöntemi olarak bilinir.

- Besleme noktası simetri bozulmuş bir şekilde iletken tabakanın üzerinde bir noktada bulunur. Bu tür besleme yöntemi merkez dışı besleme yöntemi olarak bilinir.
- Besleme noktası iletken tabakanın hemen altında olacak şekilde yer almaktadır. Bu tür besleme yöntemi değişik besleme yöntemi olarak bilinir.

Şekil 2.14' de eş eksenli hat ile besleme yöntemi şematik olarak gösterilmiştir.



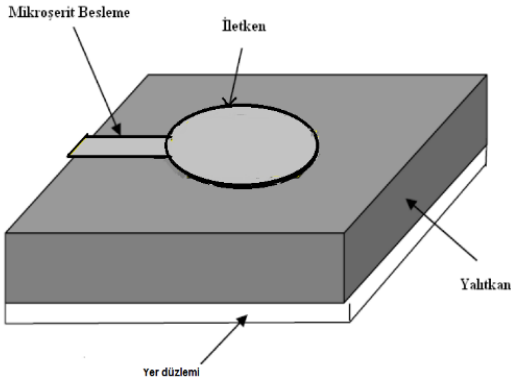
Şekil 2.14. Es eksenli hat ile besleme.

2.3.3.4.2 Mikroserit Hat ile Besleme

Mikroserit Hat ile Besleme yönteminde, anten gibi aynı baskı devre üzerinde bir besleme hattı oluşturulur. Bu tarz besleme de empedans uyumunun sağlanmaması gibi bir sorunla karşılaşıldığında uyumsuzluğun olduğu noktalarda besleme girişine bir uydurma devresi konularak uyum sağlanabilir. 2 farklı türde besleme yapılabilir. Bunlar;

- Mikroşerit hattın antene simetrik olarak yerleştirildiği besleme türüdür. Bu besleme merkezi besleme olarak isimlendirilir.
- Mikroşerit hat ile anten simetrik değildir. Bu besleme türüne de merkez dışı besleme adı verilir.

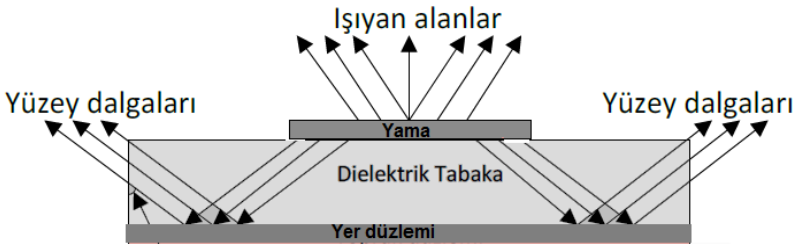
Üretimi ve modellenmesi en kolay olan besleme tekniği olmasına karşın antende kullanılan dielektrik tabaka kalınlığının artması parazitik ışımanın da artmasına sebebiyet verir. Bu durum bant genişliğini sınırlar (Balanis, 2016). Mikroşerit hat ile besleme yöntemi Şekil 2.15'de gösterilmiştir.



Şekil 2.15. Mikroşerit hat ile besleme yöntemi.

2.3.3.5 Yama Yarıçap Hesabı

Yama antenlerde dielektrik tabakanın εr>1olması durumunda, ışıma sırasında gücün bir kısmı dielektrik tabaka içinde yayılır. Tabaka içindeki bu enerji yüzey dalgalarını oluşturur ve anten ışımasını bozar. Anten ışımanın bozulmasının nedeni bu dalgaların kenarlarda ışıma oluşumuna neden olmasıdır. Ayrıca anten elamanları arasında kuplaj etkilerini ortaya çıkartırlar. Bu nedenle yüzey dalgalarının oluşumu istenmeyen bir durumdur. Yüzey dalgalarının oluşumu Şekil 2.16'de gösterilmiştir.



Şekil 2.16. Antende meydana gelen alan çizgilerinin dağılımı ve yüzey dalgaları.

Tasarlanan antende kullanılan dielektrik tabakanın göreceli geçirgenlik değeri 4,4'tür. Bu nedenle anten yamasının daire yarıçapı, ölçümlerin yüzey dalgalarından etkilenmeyeceği şekilde seçilmiştir. Antenin rezonans frekansının 1,5 GHz olması istenmiş ve ona uygun olarak antenin yama yarıçapı Denklem (2.18) kullanılarak hesaplanmıştır.

$$a = \frac{F}{\left\{1 + \frac{2h}{\pi\varepsilon_r F\left[\ln\left(\frac{\pi F}{2h}\right) + 1{,}7726\right]^{1/2}}\right\}} \tag{2.18}$$

Buradaki F, Denklem (2.19) ile hesaplanır.

$$F = \frac{8{,}791x10^{9}}{f_r\sqrt{\varepsilon_r}} \tag{2.19}$$

Denklemlerde gösterilen simgeler,

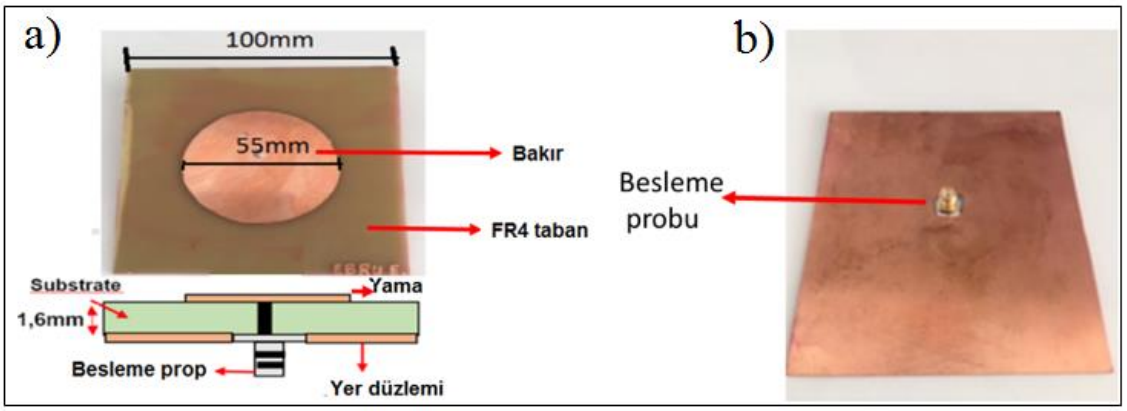
ε_r: alt tabakanın bağıl geçirgenliği

f_r: Rezonans frekansı

h: Alt tabakanın yüksekliği

a: Yama yarıçapı

temsil etmektedir. Değerler denklemlerde yerine konularak yama çapı 100 mm olarak bulunmuştur. Tasarım, 1.6 mm yükseklik, 4.4 nispi geçirgenlik ve altında 10 x 10 cm2 yer düzlemine sahip FR4 esaslı dielektrik bir alt tabaka üzerine inşa edilmiştir. Antenin geometrisi Şekil 2.17'de gösterilmiştir.



Şekil 2.17. Tasarlanan antenin geometrisi a) Antenin ön yüzü b) Antenin arka yüzü.

BÖLÜM 3

3 MAKİNE ÖĞRENMESİ

Öğrenmenin kelime anlamı, bilgi edinmek, yetenek ve beceri kazanmaktır. Öğrenme, insanın doğduğu andan başlar ve hayatı boyunca devam eder. İnsanların yaşadıkları bir sorun karşısında sahip oldukları bilgi ve beceri birikimi ile doğru kararı vermesi insanın öğrenme yeteneğini kullandığının bir göstergesidir. İnsanlardaki bu yeteneğin bilgisayarlara aktarılması ile insanların hayatının kolaylaştırılacağı düşünülmüştür. Makine ve bilgisayarların insan gibi öğrenip bir problem karşısında çözüm için gerekli en iyi kararı vermesi makine öğrenmesi kavramının ortaya çıkmasına neden olmuştur. Bilgisayarlar başlangıçta insanlara günlük hesaplamalarda yardımcı olması için tasarlanmıştı. Daha sonra bilgisayarlarda sağlanan gelişmeler ile bilgisayarların ve makinelerin basit bazı görevleri yapmaları ve istenilen verileri toplayıp depolaması sağlandı. Bilgisayarlarda toplanan bu verilerin bir işe yaramaları için bu verilerin anlamlandırılması gerekiyordu aksi takdirde toplanan verilerin bir çöp yığınından farkı kalmayacaktı. Makine öğrenmesi ile bilgisayarların insan gibi eğitilip öğretilerek verilerin analiz edilip anlamlı hale getirebilmesi gerekiyordu. Büyük miktara ve çok özelliğe sahip verileri elle işlemek mümkün olmadığından depolanan verilerin bilgisayar yardımıyla işlenerek bu verilerden anlamlı bilgi elde etmek makine öğrenmesinin temelini oluşturmaktadır. Makine öğrenmesi geçmiş deneyimler veya örnek veriler kullanır. Performans kriterini optimize eder. Makine öğrenmesi yapay zekanın bir alt dalıdır. El yazısı, nesne ve görüntü tanımada, arama motorlarında ve tıbbi teşhiste bulunma alanı gibi birçok alanda kullanılmaktadır.

3.1 Makine Öğrenmesi Teknikleri

Bu teknikler denetimli ve denetimsiz öğrenme olarak 2 gruba ayrılır. Fakat teknoloji ve algoritmalardaki gelişmeler bu tekniklere yarı denetimsiz öğrenme, pekiştirmeli öğrenme, çevrimiçi ve aktif öğrenme tekniklerinin eklenmesine neden olmuştur.

3.1.1 Denetimli Öğrenme

Girdi ve çıktıların oluşturduğu bir eğitim setinin denetleyici gözetiminde girdilerin çıktılara nasıl etki edeceğini inceler. Bu öğrenme yönteminde, daha önceki gözlemlerden eğitim seti oluşturulur ve denetleyici bunu sisteme öğretir. Denetmen öğrenilmesini istediği bir olay ile ilgili her bir örnek için bulunan girdileri ve o değerlerin karşılığında meydana getirilmesi istenen çıktıları sisteme tanıtır ve sistemden belirlediği çıktıları üretmesini ister. Böylelikle girdi-çıktı arasında nasıl bir ilişki olduğu öğrenilmiş olur. Denetimli öğrenmenin amacı, eğitim setindeki her bir girdi için alınan çıktı ile gerçek çıktı arasındaki farkı en küçüklemektir. Eğitimin sonlanması alınan çıktı ile gerçek çıktı arasındaki farka bağlıdır. Bu değerin istenen aralığa ulaşması durumunda eğitim tamamlanır. Eğitim tamamlandıktan sonra, daha önce sisteme tanıtılmamış bir nesnenin model tarafından değerlendirilip bir tahminde bulunulmaya çalışılır. Denetimli öğrenme genel olarak sınıflandırma problemlerinde kullanılmaktadır. Bu tez kapsamında sınıflandırma yöntemleri kullanılacaktır.

3.1.2 Denetimsiz Öğrenme

Adından da anlaşılacağı gibi her hangi bir denetleyici bulunmadan girdi değişkenlerine sahip gözlemlerden oluşur. Sisteme sadece girdi değişkenlerine sahip gözlemler verilir. Hedef çıktı verilmez (Flinton & Sejnowski, 1999) . Sistem denetleyici kullanmadan tek başına öğrenimini gerçekleştirir ve girdi değişkenleri arasındaki ilişkiyi bulmaya çalışır. Denetimsiz öğrenmede amaç, gözlemler arasından yakın özelliklere sahip örnekleri aynı kümede toplamaktır.

3.1.3 Yarı Denetimsiz Öğrenme

Bu öğrenmede sınıflandırma yapmak için hem etiketlenmiş hem de etiketlenmemiş örnekleri kullanılır. Genellikle etiketlenmemiş veri miktarı etiketlenmiş veri miktarından fazladır. Etiketsiz bütün verilerin hepsinin etiketlenmesi zor olduğundan yarı-denetimsiz öğrenme pratik bir çözüm olarak düşünülebilir. (Blum & Mitchell, 1998; Chapelle, Scholkopf, & Zien, 2009; Huang, Kecman, & Kopriva, 2006). Bu tür öğrenme hedef çıktısını elde etmenin zor olduğu durumlarda kullanımı tercih edilir.

3.1.4 Pekiştirmeli Öğrenme

Bu öğrenme türünde algoritma verilen gözlemlerin nasıl gerçekleşeceğini öğrenir. Çevrede meydana gelen bütün hareketler bir takım etkilere sahiptir. Çevre, öğrenme yöntemine rehberlik eden bir geri besleme sağlamaktadır (Fu & Anderson, 2006; Littman & Moore, 1996; Sutton & Barto, 1998); Bertsekas & Tsitsiklis, 1995). Çevre, durumlara karar vermek için matematiksel bir çatı sağlayan bir Markov Karar işlemi olarak formüle edilir. Böylelikle algoritma dinamik programlama yöntemleriyle öğrenmeyi gerçekleştirir. Bu öğrenme kuramında öznelerin en fazla ödül miktarını elde etmek için hangi eylemleri yaptığı ile ilgilenir. Makine öğrenmesinde ortam genel olarak bir Markov Karar Süreci olarak modellenmektedir. Bu öğrenme algoritmalarının diğer yöntemlerden farkı Markov Karar Süreci ile ilgili ön bilgiye gerek duymamaları ve kesin yöntemlerin verimli olmadığı büyük Markov Karar Süreçleri için kullanılmalarıdır. Denetimli öğrenmeden, doğru girdi/çıktı eşleşmelerinin verilmemesi ve iyi olmayan eylemlerin dışardan müdahale edilmemesi yönleriyle ayrılır. Bu öğrenmede bilinmeyen uzayda keşif ile var olan bilgiden yararlanma arasında bir denge kurmaktan söz edilir. Ortamı algılayan ve kendi kararlarını kendi alabilen bir sistemin, hedefine varabilmesinde doğru kararlar almayı nasıl öğrenebileceğini gösteren bir öğrenme yöntemidir. Sisteme ulaşması gereken bir hedef verilir. Sistem deneme-yanılma yolunu kullanarak hedefe nasıl varacağını öğrenir. Bu öğrenmeyi yapabilmek için sistem denetimli öğrenme ve dinamik programlama alanlarını birleştirir (Kartal, 2015). Sisteme gerçekleştirdiği her eylemden sonra ödül ya da ceza verilir. Sistem gerçekleştirdiği eylemleri göz önünde bulundurarak yapacağı sonraki eyleminde ödül kazanmayı hedefler. Burada amaç sistemin kazandığı ödül sayısını maksimuma çıkarmaktır. Robotik, oyun programlama, fabrika otomasyonu vb. alanlarda sıkça kullanılmaktadır.

3.1.5 Uyum Sağlama Yoluyla Öğrenme

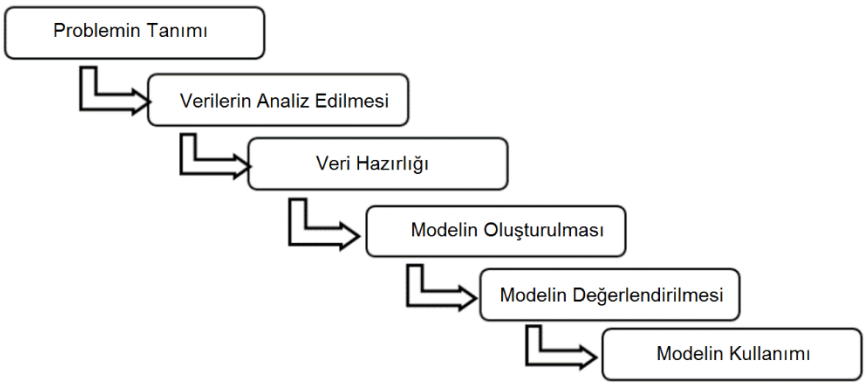
Uyum Sağlama ile öğrenme yöntemi gözetimli öğrenme tekniğine benzerlik gösterir ancak kesin bir fonksiyonu bulunmamaktadır. Uyum Sağlama ile öğrenmeyi ilk kez Vladimir Vapnik 1990'lı yıllarda tanıtmıştır (Vapnik, 1999).

3.1.6 Öğrenmek İçin Öğrenme

Bu öğrenme yöntemi kazanılan deneyimleri temel alır ve kendi tüme varım yöntemine eğilimiyle öğrenme işlemini gerçekleştirir (Thrun, 1996; Caruana, 1993; Baxter, 2000). Geliştirilen yöntemlerin birçoğu altı öğrenme türünden denetimli ve denetimsiz öğrenme yöntemini kapsamaktadır.

3.2 Makine Öğrenmesi Süreç Aşamaları

Çözülmesi gereken bir problem olduğunda makine öğrenmesi yöntemlerinin yardımıyla problemi çözmek için izlenmesi gereken yol şu adımlardan geçmektedir (Shearer, 2000). Makine öğrenmesi süreci adımlarını gösteren diyagram Şekil 3.1' de verilmiştir.



Şekil 3.1. Makine öğrenmesi süreç aşamaları.

Problemin hedeflenen zamanda başarıyla çözülmesi için burada belirtilen aşamalar oldukça önemlidir.

3.2.1 Problemin Tanımı

Makine öğrenmesiyle problem çözümünün ilk aşamasında problem en iyi şekilde tanımlanmalı, çözüme ulaşılmak istenen amaç açıkça belirtilmelidir. Bunun belirlenmesi, istenilen sonuca ulaşmasında projede çalışan araştırmacı için önemlidir. Çünkü araştırmacıların problem çözümünde nasıl bir yol izleyeceğine dair bir kanaate varmaları problemin tanımının açıkça belirlenmesi ile mümkün olur. Problemin tam olarak belli olmadığı bir çalışma, çalışanları zor durumda bırakacaktır. Bu aşamada problemin tanımı ile birlikte başarı kriterinin ne olduğu da açıkça belirtilmelidir. Şuan içinde bulunulan durum analiz edilmelidir**.** Çünkü bu başarı kriteri göz önünde bulundurularak alınan çıktılar yorumlanacaktır. Yorumların doğru yapılabilmesi için başarı kriterinin belirlenmesi önemlidir.

3.2.2 Verilerin Analiz Edilmesi

Uygulamanın 2. aşamasında probleme uygun verilerin toplanmasıdır. Verilerin elde edilmesi iki türlü olabilir. Birinci yol, mevcut veri tabanlarından veriler elde edilebilir**.** Diğer yol, anket, tartışma ya da bazı ölçümler vb. yapılarak veriler elde edebilir. Toplanan verilerin formatı niceliği sayısı incelenir. Veri setinde modelde kullanılacak olan temel özelliğin bulunup bulunmadığına dikkat edilmesi gerekir. Örnek verecek olursak; çalışmada canlı türü mühim bir özellik olmasına rağmen toplanmış veriler bütün canlı türlerini içermiyorsa veri seti değiştirilebilir ya da eksik canlı türlerine ait veriler veri tabanına eklenmelidir (Shearer, 2000).

3.2.3 Veri Hazırlığı

Verilerin temin edilip veri analizi yapılmasından sonraki aşama verilerin makine öğrenmesi algoritmalarında kullanabilecek hale getirilmesidir. Bu verileri kullanılabilecek hale getirmek için verilere, veri filtreleme, dönüşüm ve veri indirgeme gibi bazı ön işlemler yapılması gerekmektedir. Hangi işlemin yapılacağı veriden veriye farklılık göstermektedir. Verilerin temizlenmesinde genel olarak 2 işlem yapılması söz konusudur. İlk olarak her veri setinde tutarsız ya da hatalı bilgiler içeren veriler bulunabildiğinden bu verilerin veri setinden atılması işlemidir. Veri temizlemede yapılan ikinci işlem ise, kayıp değer diye bilinen verilerin atılmasıdır. Bazı durumlarda farklı

değerler ölçülememekte ya da gözden kaçmaktadır. Bu gözden kaçan değerlere kayıp değer adı verilir. Kayıp değerler sonucu etkilemeyecek sayıda ise veri setinden bu verilerin çıkartılması gerekir. Kayıp verilerin veri setine kattığı anlam fazlaysa, kayıp değerlere o özelliğe ait ortalama değer verilebilir ya da veri setinde en fazla tekrar eden değer verilebilir ya da regresyon yapılarak kayıp değerler veri setine kazandırılabilir. Veri bütünleştirme ve dönüştürme işleminde veri setindeki ifadelerin aynı dilde ve aynı biçimde ifade edilmesi sağlanmaktadır. Çünkü farklı biçimde aynı durumun gösterilmesi ifadenin farklı algılanmasına neden olabilmektedir. Verilerin hazırlanması aşamasında kullanılan bir başka işlem de verileri daha kolay ve daha hızlı işleyebilmek için yapılan indirgeme işlemidir. İndirgeme işlemi yapılırken sonuçları değiştirmeyecek şekilde veri sayısın ya da değişken sayısı azaltılır. Veri indirgeme işlemi için kullanılan birçok yöntem bulunmaktadır. Verinin hazırlanması aşamasında veriye problemin ve verilerin yapısı dikkate alınarak normalizasyon ve veri ölçekleme yapılabilir.

3.2.4 Modelin Oluşturulması

En iyi sonucu elde etmek için hangi yöntemi kullanacağına karar vermede deneme yanılma tekniğini kullanılır. Bu aşamada, veri setinde bulunan değişkenlerin aralarındaki ilişkiyi en iyi şekilde çözümleyebilen ona uygun model ve algoritmanın saptandığı adımdır. Veri setinden yüksek verim alabilmek için birden fazla model oluşturulup birden fazla algoritma denenmeli ve en iyi sonuca ulaşılmaya çalışılmalıdır.

3.2.5 Modelin Değerlendirmesi

Makine öğrenmesi yöntemleri ile veri setlerinden modeller oluşturulduktan sonra değerlendirme yapılarak hangi modelin daha uygun olduğuna karar verilir. Bu kararı verebilmek için sadece eğitim veri setinin kullanımı uygun değildir. Modeli sadece eğitim veri seti kullanarak performans değerlendirmesi yapmak aşırı uyuma neden olabilir. Bu durumla karşılaşmamak ve modele daha önce tanıtılmayan veri seti üzerinde ne kadar başarılı olacağını anlayabilmek için model performans değerlendirme yöntemleri kullanılır. Çünkü aşırı uyum probleminde model çalıştığımız veri seti üzerinde mükemmel sonuçlar vermesine rağmen daha önce hiç görmediği bir veri seti üzerinde başarısız tahminler yapar. Daha önceden geliştirilmiş birçok performans değerlendirme yöntemi ve ölçütü mevcuttur. Model performans değerlendirme yöntemlerinden en çok

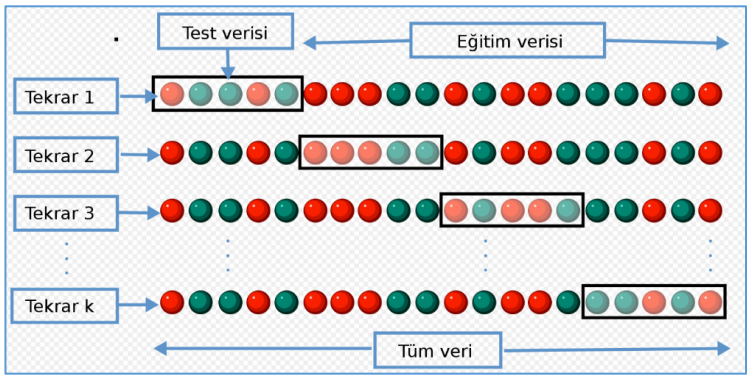
kullanılan yöntemler K – katlamalı çapraz doğrulama yöntemi ve dışarıda tutma yöntemidir.

3.2.5.1 Dışarıda Tutma Yöntemi

Veri seti eğitim ve test olmak üzere iki parçaya ayrılır. Parçaların ayrılmasında genelde kullanılan oran %65'e %35'tür.Verilerin %65'i eğitim veri seti olarak %35'ü de test veri seti olarak kullanılır (Izadi, Ranjbarian, Ketabi, & Nassiri-Mofakham, 2013).Test veri setinde kullanılan veriler eğitim setinde kullanılmaz. Model kurma eğitim seti kullanılarak yapılır. Test veri seti kullanılarak öğrenmenin ne ölçüde gerçekleştiğinin kontrolü yapılır ve model performansı elde edilir. Gözlem sayısı az olan veri setlerinde bu yöntem kullanıldığında ayırmanın yeterince iyi olmadığı görülmüştür. Ayrıca veri setinin eğitim ve test verisi olarak bir defalık ayrılması, bütün verinin modelde kullanılamaması bu yöntem için dezavantajdır. Yöntemin bir başka dezavantajı da, eğitim setinden ayrı tutulan veriler arasında modele iyileştirici katkı sunacak verilerin bulunabilme ihtimalidir.

3.2.5.2 K – Katlamalı Çapraz Doğrulama

Bu teknikte, veri seti rasgele k değeri kadar parçaya bölünür. K-1 parçası eğitim için kullanılır 1 parçası da test için kullanılır ve bu işlem k defa tekrar edilir. Her seferde bulunan değerler toplanır ve bu değerlerin ortalaması alınır. K – katlamalı çapraz doğrulama tekniğinin şematik gösterimi Şekil 3.2 'te verilmiştir. K sayısı genellikle 10 olarak seçilir.



Şekil 3.2. *K* – katlamalı çapraz doğrulama tekniği.

3.2.5.2.1 Model Performans Değerlendirme Ölçütleri

Model performans metrikleri bir sınıflandırma yapma işlemi için oluşturulan modelin başarısı, genellikle doğru tahminlerin sayısı gibi düşünülür. Fakat doğru tahminlerin sayısı sadece sınıflandırmanın doğruluğunu gösterir. Oluşturulan modelin ne derecede iyi olduğuna anlamak için bu sayı tek başına yeterli olmaz. Hata matrisi, bir sınıflandırma algoritmasının tahmin sonuçlarını göstermenin en açık yoludur. Bir hata matrisi, oluşturulan modelin performansını ortaya çıkarmakta sıklıkla kullanılır. 4 parametreden oluşur (Joshi, 2016).

3.2.5.2.1.1 Hata Matrisi

Bir karışıklık matrisi, bir sınıflandırma sistemi tarafından yapılan gerçek ve öngörülen gruplar hakkında bilgi içerir. Denetimli bir öğrenme yönteminin performansının görselleştirilmesidir. Bir hata matris gösterimi Çizelge 3.1'de verilmiştir.

Çizelge 3.1. Hata matrisi.

		Tahmin edilen sınıf	
Gerçek sınıf		Pozitif	Negatif
	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Doğru Pozitif (DP) ; Doğru sınıflandırılan pozitif değerleri ifade eder. Bu değer, gerçek sınıfın ve algoritmanın bulduğu sınıfın aynı olduğunu gösteren bir değerdir. Bu tezde tehlikeli sıvıyı tehlikeli sıvı olarak tahmin ettiğinde DP değeri bulunmaktadır.

Doğru Negatif (DN); Bu değerler doğru sınıflandırılan negatif değerleri ifade eder ve gerçek sınıf ile sınıflandırılan sınıfın aynı olduğunu gösterir. Burada, tehlikesiz sıvıyı, tehlikesiz sıvı olarak sınıfladığımızda DN değeri bulunmaktadır.

Yanlış Pozitif (YP); Gerçek sınıf ile sınıflandırılan sınıfın aynı olmadığı durumda ortaya çıkar. Burada bir tehlikesiz sıvıyı, tehlikeli sıvı olarak sınıfladığımızda YP değeri bulunmaktadır.

Yanlış Negatif (YN); Bunlar gerçek sınıflar ve sınıflandırma sonucu bulunan sınıflar farklı olduğu durumları ifade eder. Bu tezde tehlikeli bir sıvıyı, tehlikesiz sıvı olarak sınıfladığımızda YN değeri bulunmaktadır. Sınıflandırma performansının yüksek olması için doğru pozitif ve doğru negatif bölgelerin artması, yanlış pozitif ve yanlış negatif bölgelerin azaltılması istenir. Hata matrisinden aşağıdaki metrikler hesaplanabilir.

Doğruluk: Model başarısının ölçülmesi için en sık kullanılan metot, modelin doğruluk oranını bulmaktır**.** Bu oran doğru tahmin edilen gözlemlerin sayısının toplam gözlemlerin sayısına bölünmesi ile elde edilir Denklem (3.1). Kullanılan modelin doğruluk oranının yüksek çıkması modelin iyi olduğunu gösterir ve mümkün olduğunca yüksek bir doğruluk oranı istenir. Fakat yanlış pozitif ve yanlış negatif değerlerinin sayılarının fazla olması durumunda model performans değerlendirmede kullanılan diğer parametrelerin de incelenmesi gerekir (Joshi, 2016; Sturm, 2013).

$$\text{Doğruluk} = \frac{\text{DoğruPozitif} + \text{DoğruNegatif}}{\text{DoğruPozitif} + \text{YanlışPozitif} + \text{DoğruNegatif} + \text{YanlışNegatif}} \tag{3.1}$$

Duyarlılık: Doğru pozitif gözlem sayısının, bulunan toplam pozitif gözlem sayısına bölünmesi ile elde edilir. Bu oran sınıflandırma algoritmasının kesinliğinin bir ölçüsü olarak ta düşünülebilmektedir. Duyarlılık değerinin düşük olması çok sayıda yanlış pozitif olduğunun da bir göstergesi olarak sayılabilir (Joshi, 2016; Brownlee, 2014). Duyarlılık hesabını veren bağıntı Denklem (3.2)'de verilmiştir.

$$\text{Duyarlılık} = \frac{\text{DoğruPozitif}}{\text{DoğruPozitif} + \text{YanlışPozitif}} \tag{3.2}$$

Hassasiyet: Sınıfı doğru olarak bulunan gözlemlerin, toplam pozitif sayısına oranlanması ile hesaplanır. Hassasiyet sınıflandırma algoritmasının bütünlüğünün bir ölçüsüdür. Düşük hassasiyet değeri, yanlış negatiflerin sayısının fazla olduğu anlamına gelir (Joshi, 2016; Brownlee, 2014). Hassasiyet metriği Denklem (3.3) kullanılarak hesaplanabilir.

$$\text{Hassasiyet} = \frac{\text{Doğru Pozitif}}{\text{YanlışNegatif} + \text{DoğruPozitif}} \tag{3.3}$$

F-skoru: F-skorunun 1 ile 0 arasında değerler alır. Genel olarak, modelinizin kesinliğinin ve sağlamlığının bir ölçüsüdür. Bu değerin hesaplanması için hassasiyet ve duyarlılık metrikleri kullanılır. Bu değerlerin harmonik ortalaması F-skorunu verir. Bu sebeple, sadece yanlış pozitif ya da yanlış negatifleri kullanmaz her ikisini de hesaba katar. Özellikle bu değere bakmak düzensiz sınıf dağılımının olduğu durumlarda daha faydalıdır. Yanlış pozitiflerin ve yanlış negatif değerlerin sayıları çok farklıysa, sadece hassasiyet değerine değil aynı zamanda duyarlılık değerine de bakmak gerekmektedir (Joshi, 2016; Brownlee, 2014). Örneğin iki modeli düşük kesinlik ve yüksek duyarlılık ile karşılaştırmak zordur veya tersi de geçerlidir. Bu yüzden onları karşılaştırılabilir hale getirmek için F1 skoru kullanılır. F-skoru Denklem (3.4)'deki gibi hesaplanır.

$$\text{F_Skoru} = \frac{2 * \text{Hassasiyet} * \text{ Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \tag{3.4}$$

3.2.5.2.1.2 Kappa İstatistiği

Bu değer bir veri setinde, sınıflandırma sonucu yapılan sınıflandırma ve gerçek sınıflandırmalar arasında ne kadar uyum olduğunu ölçmede kullanılır. Kappa değerinin nasıl bulunduğu Denklem (3.5)'te verilmiştir. P(a) sınıflandırma algoritmasının doğruluğunu olasılıksal olarak gösteren bir değerdir ve P(e) aynı veri setinde yapılan sınıflandırmaların olasılığının ağırlıklı ortalamasıdır. Bu değer -1 ve 1 aralığında değişir. Değerin -1 olması tam bir uyumsuzluğu yani ters yönlü bir ilişki olduğunu, değerin 1 olması ise mükemmel uyum gösterdiğini ifade etmektedir. Değer 1'e yaklaştıkça uyum artarken uzaklaştıkça uyum azalır. Kapa değeri ve yorumu Çizelge 3.2'de gösterilmiştir.

$$\text{Kappa} = \frac{\text{P(a)} - \text{P(e)}}{1 - \text{P(e)}} \tag{3.5}$$

Çizelge 3.2. Kappa değeri

Kappa değeri	Yorum
<0	Hiç uyum yok
0,0-0,20	Az uyum var
0,21-0,40	Orta derecede uyum var
0,41-0,60	Çoğunlukla uyum var
0,61-0,80	Fazla uyum var
0,81-1	Hemen hemen mükemmel uyum var

En çok kullanımı tercih edilen hata metrikleri şunlardır:

3.2.5.2.1.3 Kök Ortalama Kare Hatası (KOKH)

Gerçekteki değerler ile model tarafından öngörülen değerler arasındaki farklılıkları ölçeklendirmek için kullanılır. Ortalama kare hatasının karekökü alınarak belirlenir ve Denklem (3.6)'da yer alan bağıntı ile hesaplanır.

$$H_i = \sqrt{\frac{1}{n}\sum_{j=1}^{n}\left(T_{ij} - A_j\right)^2} \tag{3.6}$$

Burada Tij tahmin edilen değer Aj amaç değerdir. Hata değerinin sıfıra yaklaşması sınıflandırma algoritmasının doğru tahminin artması anlamına gelir.

3.2.5.2.1.4 Ortalama Mutlak Hata (OMH)

Veri kümesinin tüm örneğinde, o örnek için gerçek değer ile öngörülen değer arasındaki her bir farkın mutlak değerinin ortalamasının alınması ile Denklem (3.7) kullanılarak hesaplanır.

$$H_i = \frac{1}{n}\sum_{j=1}^{n}\left|T_{ij} - A_j\right| \tag{3.7}$$

3.2.5.2.1.5 Bağıl Mutlak Hata (BMH)

Göreceli mutlak hata, toplam mutlak hatayı alır ve basit öngörücünün toplam mutlak hatasına bölerek normalleştirir. Matematiksel gösterimi Denklem (3.8)'de verilmiştir.

$$H_i = \frac{\sum_{j=1}^{n}\left|T_{ij} - A_j\right|}{\sum_{j=1}^{n}\left|A_j - \bar{A}\right|} \tag{3.8}$$

Burada $\bar{A}$ Denklem (3.9) ile hesaplanabilir.

$$\bar{A} = \frac{1}{n}\sum_{j=1}^{n} A_i \tag{3.9}$$

3.2.5.2.1.6 Kök Bağıl Kare Hata (KBKH)

Kök bağıl kare hatası, toplam kare hatasını alır ve basit öngörücünün toplam kare hatasına bölerek normalleştirir Denklem (3.10). Göreli kare hatanın karekökünü alarak, hatayı tahmin edilen miktarla aynı boyutlara indirir.

$$\mathrm{H_i} = \sqrt{\frac{\sum_{\mathrm{j=1}}^{\mathrm{n}}(\mathrm{T_{ij}} - \mathrm{A_j})^2}{\sum_{\mathrm{j=1}}^{\mathrm{n}}(\mathrm{A_j} - \bar{\mathrm{A}})^2}} \tag{3.10}$$

Burada, $\bar{\mathrm{A}}$ Denklem (3.11)'deki gibi hesaplanır.

$$\bar{\mathrm{A}} = \frac{1}{\mathrm{n}}\sum_{\mathrm{j=1}}^{\mathrm{n}} \mathrm{A_j} \tag{3.11}$$

3.2.6 Modelin Kullanımı

Çözülmesi istenen problemi çözecek model değerlendirmesi yapılıp modelin belirlenmesinin ardından o model rahatlıkla problemin çözümünde kullanılarak istenen sonuca varılabilir.

3.3 Sınıflandırma ve Sınıflandırma Algoritmaları

Sınıflandırma; nesneleri sınıflara ayırmak için sınıfı belli olan verileri kullanan bir denetimli öğrenme yöntemidir. Yani sınıfını bilmediğimiz bir nesnenin, o nesneye ait özniteliklerini kullanıp bir model yardımıyla hangi sınıfa ait olduğunu bulma işlemidir (Baldi, Brunak, Chauvin, Andersen, & Nielsen, 2000).

3.3.1 Doğrusal Diskriminant Analizi (DDA)

Bu yöntem nesneleri sınıflandırmak için ayırma işlemi yapan istatistik yöntemlerinden biridir. Ayırma işlemi yapılırken sınıflar arası kareler toplamının, sınıf içi kareler toplamına oranını maksimum yapacak doğrusal bileşen bulunmaya çalışılır (Ünal, 2006). Sınıflandırılacak nesneler r adet özelliğe sahip olduğu varsayılırsa doğrusal ayırımda kullanılacak diskriminant fonksiyonu Denklem (3.12)'de verildiği gibidir.

$$L_{kn} = a_0 + a_1 x_{1kn} + a_2 x_{2kn} + \cdots + a_r x_{rkn} \; ; \qquad i = 1,2, \ldots\ldots, k \tag{3.12}$$

L_i: i. Diskriminant fonksiyonunu gösterir ise, bu fonksiyonun katsayıları Denklem (3.13)'de gösterildiği gibi olur.

$$a_{ij} = M^{-1}(V_i) \; ; \qquad i = 1,2 \ldots\ldots, k; \qquad j = 1,2, \ldots\ldots, r \tag{3.13}$$

Burada; M^{-1}, Ortak varyans-kovaryans matrisinin tersini, V_i ise i. sınıfın ortalama vektörünü temsil etmektedir. Denklem (3.14)'de te verilen eşitlik sabit değer denklemidir ve denklemdeki $(V_i)^T$, i. sınıfın ortalama vektörünün transpozudur.

$$a_{i0} = -\left(\frac{1}{2}\right)(V_i)^T M^{-1}(V_i); \qquad i = 1,2 \ldots\ldots, k \tag{3.14}$$

Diskriminant fonksiyonun karar kuralı Denklem (3.15)'de verilen,

$$L_i(X_i) = \max\{L_1(X_i), L_2(X_i), \ldots\ldots\ldots L_m(X_i)\} \; ; \qquad i = 1,2, \ldots\ldots, k \tag{3.15}$$

şekli alır. Sınıflar arasında benzerlik söz konusu ise ortak diskriminant fonksiyonu olarak adlandırılan tek bir diskriminant fonksiyonu oluşturulur ve bu fonksiyonuna ait katsayılar, Denklem (3.16)'da vasıtasıyla bulunur (Sangün, 2007).

$$a_{12} = M^{-1}(V_1 - V_2) \tag{3.16}$$

Denklemde a_{12}, birinci ve ikinci bileşen katsayılarının ortak vektörünü, V_1 ve V_2, birinci ve ikinci sınıfa ait ortalama vektörleri göstermektedir. Sabit değer (a_0); Birinci fonksiyona ait sabit değer ile ikinci fonksiyona ait sabit değerin toplamının ikiye bölünmesi ile elde edilir Denklem (3.17).

$$a_0 = \left(\frac{a_{10}+a_{20}}{2}\right) \tag{3.17}$$

r adet özelliğe sahip iki nokta arasındaki en büyük uzaklığın bulunmasında Mahalanobis uzaklığı kullanılır. Mahalanobis uzaklığı Denklem (3.18)'de gösterildiği gibi hesaplanır.

$$D_{ij}^2 = (V_1 - V_2)^T M^{-1}(V_1 - V_2) \tag{3.18}$$

Sınıfı bilinmeyen herhangi bir nesnenin hangi sınıfa ait olduğunun tahmin edilmesinde kullanılan karar verme kuralı Denklem (3.19)'da gösterildiği gibidir.

$$(V_1 - V_2)^T M^{-1} X_0 \geq \left(\frac{1}{2}\right)(V_1 - V_2)^T M^{-1}(V_1 + V_2) \tag{3.19}$$

Bu kural kullanılarak sınıflandırma yapılır (Sangün, 2007). Burada X_0: Herhangi bir nesneye ait özelliği göstermektedir.

3.3.2 Kuadratik Diskriminant Analizi (KDA)

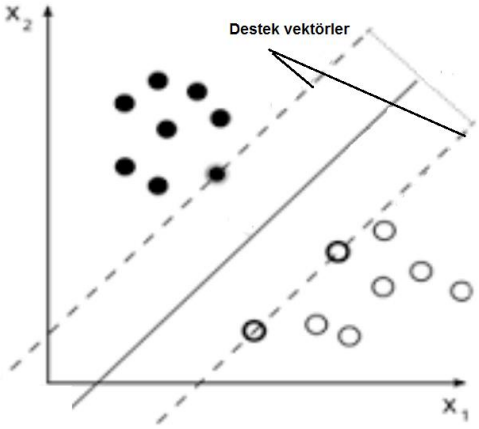
Bu algoritma ikinci dereceden karar sınırlarına sahiptir ve iki ya da daha fazla sınıfa ait nesneleri sınıflandırabilir. Verilerin normal dağılış gösterip sınıflar arası varyans-kovaryans matrislerinin aynı olmadığı hallerde kullanılan bir algoritmadır (Akbaba & Atakan, 2005).Uygulamada her bir sınıftaki gözlem sayısının değişken sayısından fazla olması gerektiği göz önüne alınmalıdır. KDA ile LDA arasındaki fark, KDA'nın her sınıf için kovaryans matrisini tahminde bulunmasıdır. Kullanılan diskiriminant fonksiyonu Denklem (3.20) da verildiği gibidir.

$$L_k(x) = -\frac{1}{2}(X - V_k)^T c_k^{-1}(X - V_k) - \frac{1}{2}\ln|c_k| + \ln P(c_k) \tag{3.20}$$

Burada, c_k, k sınıfına ait kovaryans matrisi, c_k^{-1}kovaryansin tersi, $|c_k|$ kovaryans matrisin determinantını gösterir. $P(c_k)$, k sınıfının önceki olasılığıdır. V_k ortalama vektörlerdir. Sınıflandırmada kural en yüksek L değerine sahip sınıfı bulmaktır.

3.3.3 Destek Vektör Makineleri (DVM)

Algoritma iki farklı sınıfa ait örnekleri sınıflandırmak için en uygun fonksiyonu öğrenme yoluyla bulur (Özkan, 2008). Sınıflandırma yaparken iki sınıf arasına bir hat çizerek bu sınıfların ayrılmasını sağlar. Çizilen bu hat hiper düzlem olarak adlandırılır. Hiper düzlem iki sınıf örneklerine de en uzak yerde olası gerekir. İşte bu yerin bulunmasında DVM algoritması kullanılır. Bu algoritma ile doğrusal ve doğrusal olmayan verileri sınıflandırmak mümkündür çünkü DVM algoritmasında uygun bir dönüşüm kullanılarak her zaman veriler iki sınıfa ayırabilir. Verileri ayırmada kullanılan düzleme en yakın öğrenme eğrilerine destek vektör adı verilir. Şekil 3.2' de doğrusal bir DVM kullanılarak ayrılan iki sınıf hiper düzlemi ve destek vektörleri gösterilmiştir.



Şekil 3.3. Doğrusal DVM'de destek vektörler.

Denklem (3.21) kullanılarak H_0 hiper düzlem fonksiyonu hesaplanır (Özkan, 2008).

$$H_0 = W^T.x + c = 0 \tag{3.21}$$

Burada a ağırlık vektörü ve c sabit olarak tanımlanmaktadır. Denklem n tane örnek için yazılacak olursa Denklem (3.22)'deki gibi olur.

$$H_0 = \sum_{i=1}^{n} w_i . x_i + c = 0 \tag{3.22}$$

Sınıflara ait örnekler +1 ve -1 değerleri ile etiketlenir. Sınıflara en yakın olan doğrular üzerindeki noktalara destek vektörler, bu vektörlerin üzerindeki sınır düzlemlerine en uzak olan doğruya da hiper düzlem adı verilmektedir. H_1 ve H_2 ile gösterilen hiper düzlemler Denklem (3.23) ve Denklem (3.24) bağıntıları ile hesaplanır.

$$H_1 = W^T . x + c = +1 \tag{3.23}$$

$$H_2 = W^T . x + c = -1 \tag{3.24}$$

H_0 hiper düzleminin üzerinde ve altında kalanlar sırasıyla Denklem (3.25) ve Denklem (3.26)'de belirtildiği gibi olur.

$$W^T . x + c > 0, \qquad y_i = +1 \tag{3.25}$$

$$W^T . x + c < 0, \qquad y_i = -1 \tag{3.26}$$

Denklem (3.25) ile Denklem (3.26)'nin birleştirilmesi ile Denklem (3.27) elde edilir.

$$y_i . (W^T . x + c) \geq +1 \tag{3.27}$$

x_1 ile gösterilen destek vektörüyle H_2 ile gösterilen hiper düzlem arasındaki mesafe m ile gösterilir ve Denklem (3.28)'deki gibi hesaplanır.

$$m = \frac{|W^T . x + c|}{\|w\|} = \frac{1}{\|w\|} \tag{3.28}$$

Doğrusal olmayan Destek Vektör Makineleri modelinde, veriler lineer olmayan haritalama yapılıp gerçek girdi uzayından daha yüksek boyutta bulunan bir uzaya aktarılır. $X_i * X_j$ çarpımı, 3 boyutlu uzayda $\phi(X_i).\phi(X_j)$ şeklinde tanımlanmaktadır. Çekirdek donksiyonu Denklem (3.29)'da tanımlanmıştır.

$$K(X_i, X_j) = \varphi(X_i) . \varphi(X_j) \tag{3.29}$$

Çekirdek fonksiyonunun kullanımı ile direk girdi uzayındaki veriler kullanılır, φ fonksiyonunu hesaplamaya ihtiyaç duyulmaz. Aynı zamanda daha kolaydır ve düşük maliyete sahiptir. Tablo 1 de en sık kullanılan çekirdek fonksiyonları verilmiştir.

Çizelge 3.3. DVM algoritmasında sıklıkla kullanılan çekirdek fonksiyonları

Lineer	$K(X_i, X_j) = X_i^T X_j$
Polinom	$K(X_i, X_j) = (X_i^T X_j + 1)^P$
Gauss radyal temel fonksiyonu	$K(X_i, X_j) = \exp(-\|X_i - X_j\|^2 / 2\sigma^2$
Sigmoid	$K(X_i, X_j) = \tanh(KX_i^T X_j - \delta)$

3.3.4 Naive Bayes

Bayes teoremini temel alan bir sınıflandırma tekniğidir. Sınıflandırılmış örnek nesnelerin verilerini kullanır ve sınıfı bilinmeyen bir nesnenin belirlenen sınıflara ait olma olasılığını hesaplar. Bu algoritmada özelliklerin birbirinden bağımsız olduğu kabulü yapılır. Özelliklerin değeri birbirlerinin değeri ile ilgili bilgi içermezler. K özellik sayısını, t sınıf sayısını gösteren bir veri setine sahip olduğumuzu varsayalım. Sınıfı bilinmeyen bir X nesnesinin hangi sınıfa ait olduğunu belirlemek için Denklem (3.30) kullanılır ve nesnenin var mevcut tüm sınıflar için, o sınıfın elemanı olma olasılığı hesaplanır. Hesaplanan olasılık değerlerinden en fazla çıkan sınıfa nesne atanır.

$$P(A_i|X) = \frac{P(X|A_i) * P(A_i)}{P(X)} \tag{3.30}$$

Burada,

$P(A_i|X)$:X olayı olduğunda A_i olayının olma olasılığını,

$P(X|A_i)$: A_i olayı olduğunda X olayının olma olasılığını,

$P(A_i)$, $P(X)$: A_i ve X olaylarının olasılığını temsil etmektedir.

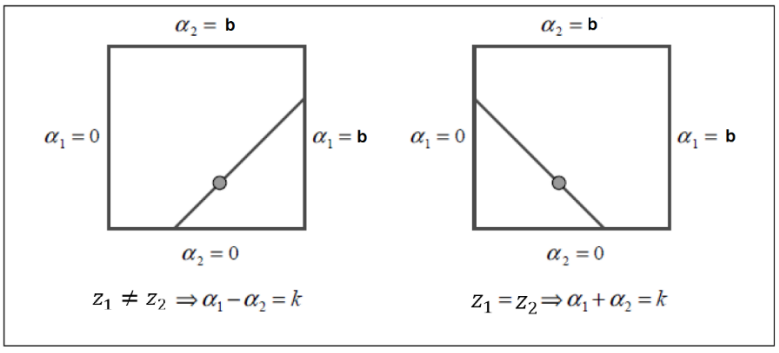
P(X) değeri bütün örnekler için aynıdır. Böylelikle denklemin sadeleşmiş hali Denklem (3.31)'de verilir.

$$P(A_i|X) = P(X|A_i) * P(A_i) \tag{3.31}$$

Her bir sınıf için Denklem (3.31)'de verilen eşitlik uygulanarak olasılıklar hesaplanır. Örnek hesaplanan değerler arasında en yüksek olasılık değerini veren sınıfa aittir (Bermejo, Gámez, & Puerta, 2011).

3.3.5 Sıralı Minimal Optimizasyon (SMO)

İlk defa John Platt tarafından 1998'de bulunan SMO algoritması, DVM ikinci dereceden programlama problemini (DVM QP) ekstra bir ek matris depolama yeri olmaksızın ve tüm sayısal ikinci dereceden programlama optimizasyon aşamalarını kullanmaya gerek duymadan hızlıca çözebilen bir algoritmadır (Platt, 1998). SMO algoritması, ayırma yöntemi düşüncesinin en uç noktaya çekilmesi ve her yinelemede yalnızca iki noktadan oluşan minimum bir alt kümenin optimize edilmesi söz konusudur. Bütün kayıp değerlerini yenileri ile değiştirir, nominal öznitelikleri ikili olanlara dönüştürür ve bütün öznitelikleri daha önce tanımlanmış değerlerle normalize eder. SMO her aşamada olabilecek en küçük optimizasyon problemini çözmeyi tercih eder. Lagrange çarpanları doğrusal bir eşitlik sınırına uymaları gerektiğinden genel DVM QP problemi için, olabilecek en küçük optimizasyon problemi iki Lagrange çarpanı ihtiva eder. Algoritma her aşamada iki Lagrange çarpanını birlikte optimize ederek bu çarpanlar için en iyi değeri bulur ve bu değeri yansıtacak biçimde DVM' yi günceme işlemini gerçekleştirir. İki Lagrange çarpanı, problemin bütün kısıtlama şartlarına uymak zorundadır. Bu kısıtlamalar, Lagrange çarpanlarının Şekil 3.4'de gösterildiği gibi kutunun içerisinde bulunmasına sebep olur. Doğrusal eşitlik kısıtı, çapraz çizgi üzerinde bulunmasına sebep olduğundan bir SMO adımı, diyagonal bir çizgi segmentindeki amaç fonksiyonun en iyisinin bulması gerekir.



Şekil 3.4. SMO Optimizasyonu (Bermejo vd., 2011).

İkinci Lagrange çarpanı α_2'yi hesaplandıktan sonra çapraz çizgi bölümünün uçlarını α_2 cinsinden hesaplanır.

$z_1 \neq z_2$ olduğunda Denklem (3.32),

$$L = \max\{0, \alpha_2^{eski} - \alpha_1^{eski}\}, H = \min\{b, b - \alpha_1^{eski} + \alpha_2^{eski}\} \quad (3.32)$$

şeklini alır. $z_1 = z_2$ olduğunda ise Denklem (3.33)'te verildiği gibi olur.

$$L = \max\{0, \alpha_2^{eski} + \alpha_1^{eski} - b\}, \; H = \min\{b, \alpha_1^{eski} + \alpha_2^{eski}\} \quad (3.33)$$

Köşegen çizgisi üzerinde amaç fonksiyonunun ikinci türevi Denklem(3.34)'te gösterildiği gibi olur ve sıfırdan büyük bir değer alır.

$$P = K(\overrightarrow{x_1}, \overrightarrow{x_1}) + K(\overrightarrow{x_2}, \overrightarrow{x_2}) - 2K(\overrightarrow{x_1}, \overrightarrow{x_2}) \quad (3.34)$$

i.eğitim örneğindeki hata değeri Denklem (3.35),

$$E_i = f(x_i) - z_i = \left(\sum_{j=1}^{l} a_j z_j + c\right) - z_i \qquad i = 1,2 \quad (3.35)$$

Şeklinde ifade edilir ve α_2^{yeni} Denklem (3.36) ile hesaplanır.

$$\alpha_2^{yeni} = \alpha_2^{eski} + \frac{z_2\{E_1 - E_2\}}{P} \quad (3.36)$$

Son olarak, sınırlandırılmış $\alpha_2^{yeni,kısıtlı}$ Denklem (3.37)'de ifade edildiği gibi bulunur.

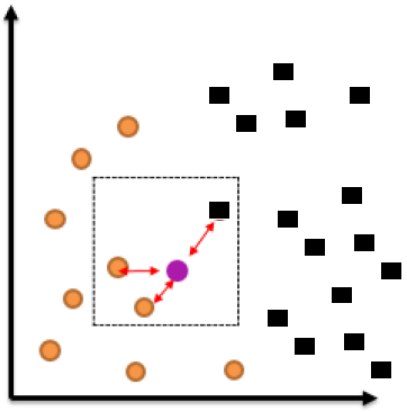
$$\alpha_2^{yeni,kısıtlı} = \begin{cases} H & \text{eğer } \alpha_2^{yeni} \geq H \\ \alpha_2^{yeni} & \text{eğer } L \leq \alpha_2^{yeni} \leq H \\ L & \text{eğer } \alpha_2^{yeni} \leq L \end{cases} \quad (3.37)$$

Daha sonra, $s = z_1 z_2$ olmak üzere, α_1^{yeni} değeri sınıflandırılmış $\alpha_2^{yeni,kısıtlı}$ kullanılarak Denklem (3.38) ile bulunur.

$$\alpha_1^{yeni} = \alpha_1^{eski} + z_1 z_2 (\alpha_2^{eski} - \alpha_2^{yeni,kısıtlı}) \quad (3.38)$$

3.3.6 En Yakın Komşu Algoritması (K-EYK)

K-EYK algoritması basit ama etkin parametrik olmayan gözetimli öğrenme yöntemlerindendir (Aci & Avci, 2011). Algoritma gürültülü veriye karşı dirençlidir. Sınıfı bilinmeyen bir örneği eğitim kümesindeki k adet komşusuna bakarak çoğunluğun etiketine göre sınıflandırılması esasına dayanır. Bu etiketlemeyi yapmanın en kolay yolu, eğitim kümesinde bulunan örneklerden bu örneğe en yakın örnekleri seçmektir. Yakınlık ve uzaklık kavramları ise farklı uzaklık metrikleri kullanılarak hesaplanır. *k* komşu sayısını ifade eden bir tam sayı değeridir. Algoritmaya göre sınıflandırmada kullanılacak özelliklerden sınıfı belirlenecek olan yeni örneğin daha önceden sınıfı bilinen, veri tabanında bulunan örneklerin *k* tanesine olan uzaklığına bakılır. Örneğin, *k*=3 için sınıfı bilinmeyen bir nesnenin sınıfını belirlemek isteyelim. Bu nesneye sınıfı bilinen nesnelerden en yakın 3 tanesi alınır. K-EYK algoritmasının komşu seçimi Şekil 3.5'te gösterilmiştir. Nesneye yakın olan bu nesneler hangi sınıfta ise yeni nesne o sınıfa aittir.



Şekil 3.5. K-EYK algoritması kullanılarak sınıflandırılacak örneğe en yakın üç komşunun seçimi.

K sayısı aynı zamanda verinin kaç sınıfa ayrılacağını gösteren bir parametredir ve Sınıflandırmadan önce algoritmaya girilmesi gereken bir sayıdır. Mesafe ölçütü olarak kullanılan ölçütlerden en sık kullanılanı Öklid mesafesidir (Lucey & Ashraf, 2013). Bunun yanı sıra Minkowski, Manhattan, Chebyschev gibi mesafe ölçütleri de vardır. Mesafe ölçütü hesabında d_{ij}=i. ve j. gözlemlerin birbirlerine olan uzaklığını ifade ederse, Öklid uzaklığı, Denklem (3.39)'daki gibi hesaplanabilir.

$$d_{ij} = \left(\sqrt{\sum_{n=1}^{t}\left(x_{in} - y_{jn}\right)^2}\right) \tag{3.39}$$

Minkowski uzaklık ölçüsü p=1 alındığında Manhattan uzaklık ölçütünü, p=2 alındığında ise Öklid uzaklık ölçütünü ifade eder. Minkowski uzaklık ölçütü Denklem (3.40)'da gösterildiği gibi ifade edilir.

$$d_{ij} = (\sum_{n=1}^{t} |x_{in} - y_{in}|^p)^{1/p} \tag{3.40}$$

Manhattan uzaklığı City-Blok uzaklık ölçütü olarak ta bilinir. Bu ölçüt değişkenler arasında korelasyon olmadığında kullanılan bir uzaklık ölçütüdür. Hesaplanışı Denklem (3.41)' deki gibidir.

$$d_{ij} = \left(\sum_{\mathbf{n=1}}^{\mathbf{t}} \left|x_{in} - y_{jn}\right|\right) \tag{3.41}$$

Maksimum değer uzaklığı olarak ta bilinen Chebyschev uzaklık ölçütü. Minkowski mesafe ölçütünün, $p \to \infty$ a gittiği durumu ifade eder. Denklem (3.42)'daki gibi hesaplanır.

$$d_{ij} = \lim_{p\to\infty}\left(\sum_{n=1}^{t}\left|x_{in} - y_{jn}\right|^p\right)^{1/p} = \max_{n=1}^{t}\left|x_{in} - y_{jn}\right| \tag{3.42}$$

Bu denklemlerde

i, j= 1,…,m; n= 1,2,…, t

xik= i. birimin n. değişken değeri

xjk=j. birimin n. değişken değeri ifade etmektedir.

Komşu sayısı (k) arttıkça örnek etrafındaki çember genişleyecektir, diğer sınıfa ait örnekler de kümeleme işlemine dahil olacaktır. Böylelikle hatalı sınıflandırma olasılığı artacaktır (Akpınar, 2014; Özkan, 2008). Bu sebeple, *k* komşu için her bir sınıfın komşularının uzaklıkları da göz önünde bulundurularak ağırlıklı oylama yapılabilir

(Özkan, 2008). Ağırlıklandırma yönteminde tüm komşular için ağırlık değerleri atanması yapılır ve sınıflandırılacak örneğe daha yakın olan komşu örneklerin ağırlık değerleri diğer komşulara göre daha fazla olacak şekildedir. Genellikle en sık tercih edilen ağırlık değeri atama yöntemi, her bir komşunun ağırlığının *1/d* şeklinde alındığı yöntemdir. Burada *d,* komşular arası uzaklığı temsil etmektedir (Doad & Bartere, 2013).

3.3.7 K-Yıldız Algoritması

Örnek tabanlı bir öğrenme algoritması olan K-yıldız algoritması, entropik uzaklık ölçüsünü kullanarak veriler arasındaki spektral mesafeyi ya da verilerin birbirlerine benzerliğini belirler (Cleary & Trigg, 1995). Bu uzaklık bilgi teorisine dayanmaktadır. Bilgi teorisine göre, entropi rastgele değişkenlerin belirsizliğin ölçüsü olarak görülmektedir (Shannon, 2001). Veriler arası mesafe hakkında tahmin bir verinin başka bir veriye dönüşümündeki karmaşıklıktır. Bu karmaşığın hesabı iki aşamalıdır. Birinci adım, özellikten özelliğe dönüşümlerden oluşan dönüşümler kümesi, İkinci adım bir özelliğin (c) başka bir özelliğe (d) dönüşümü, (c)'dan başlayarak (d)'de biten dönüşümler serisidir (Cleary & Trigg, 1995). Bu algoritma Kolmogorov mesafesini kullanarak iki özelliği birbirine bağlayan en kısa uzaklığı hesaplamaktadır. Böylelikle K-yıldız mesafesi, iki özellik arasında bulunan bütün dönüşümlerin toplanması ile bulunur (Piramuthu & Sikora, 2009) t dönüşümleri ile c özelliğinden d özelliğine olan bütün yollar için olasılık fonksiyonu P* Denklem (3.43)' deki hali alır.

$$P^*\left(\frac{d}{c}\right) = \sum_{\bar{t}\in P:\bar{t}(c)=d} P(\bar{t}) \tag{3.43}$$

K-Yıldız (K*) fonksiyonunun gösterimi ise Denklem (3.44)' te verilmiştir.

$$\mathrm{K}^*\left(\frac{\mathrm{d}}{\mathrm{c}}\right) = -\log_2(\mathrm{d}/\mathrm{c}) \tag{3.44}$$

Bu fonksiyon sayısal ya da sembolik veri setleri için kullanılabilen bir fonksiyondur. Fonksiyon eğer sayısal sınıf değerler için kullanılıyorsa, x_0 parametresi eğitim öncesinde kullanıcı tarafından belirlenmektedir. Hem sayısal hem de sembolik veriler için kullanımda örnek sayısı, 1 değeri ile M değeri arasında değişmektedir (Cleary & Trigg,

1995). Herhangi bir P* fonksiyonu için etkili örnek sayısı, Denklem (3.45)'te gösterildiği gibi olur.

$$m_0 \leq \frac{(\sum_d P^*(d/c))^2}{\sum_d P^*(d/c)^2} \leq M \tag{3.45}$$

Burada;

M, Bütün eğitim örneklerinin sayısı,

m_0, Eğitim örneklerinden *c* örneğine en yakın örneklerin sayısı

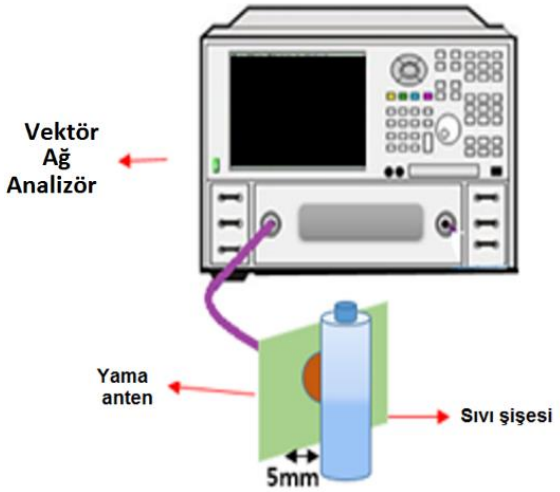
x_0 ve s parametreleri için *c* değeri m_0 ve M arasındaki bir değer seçilmesi ile belirlenir. Böylelikle seçilmiş olan m_0 en yakın komşuluk algoritmasını ve seçilmiş olan M eşit ağırlıklı örneklerin sayısını gösterir. Harmanlama parametresinin (d) kullanımı ile belirlenen bu sayıların uygunluğu saptanır. Harmanlama parametresi d=0 % (n_0 için) d =%100 % (M için) arasında değişir.

BÖLÜM 4

4 MİKRODALGA VERİLERİNİN SINIFLANDIRILMASI

4.1 Mikrodalga Verilerinden Tehlikeli Sıvı Tespiti

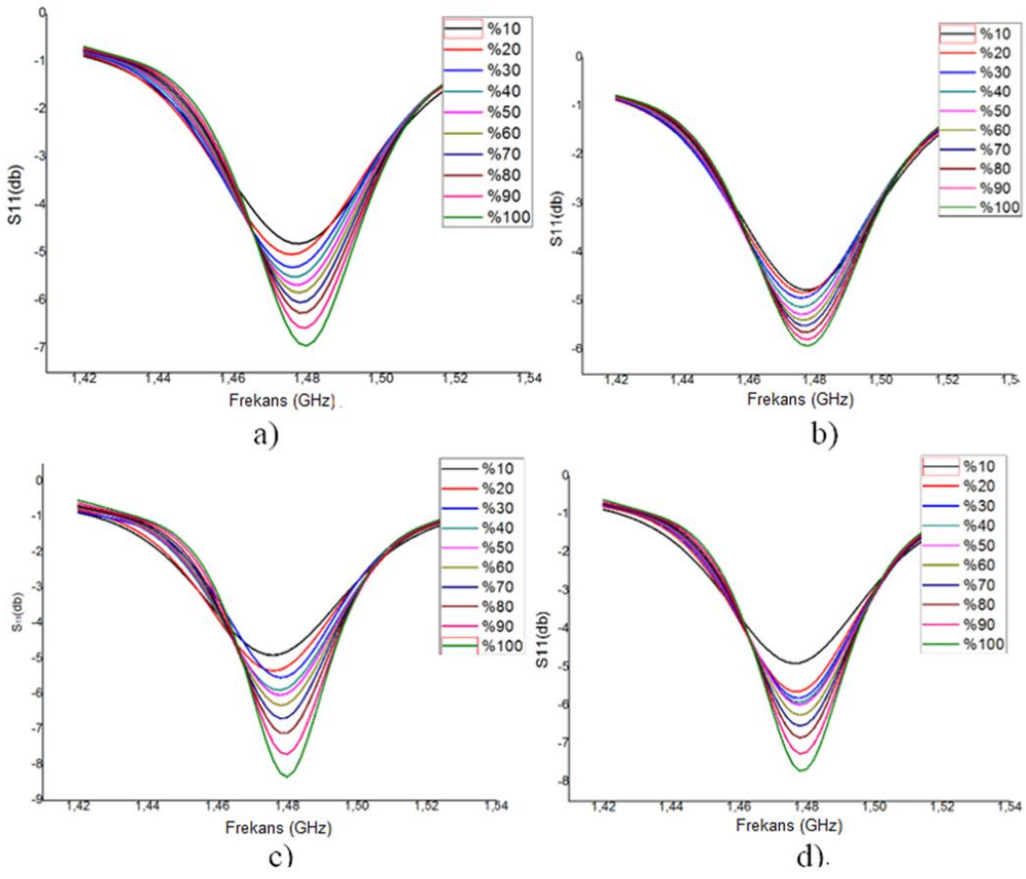
Tehlikeli sıvıların tespiti için 24 tane tehlikeli ve 53 tane tehlikesiz olmak üzere 77 tane sıvının s-parametresi (S_{11}) ölçümü yapılmıştır. Kullanılan ölçüm seti Şekil 4.1'de verilmiştir. Ölçümlerde kullanılan sıvılar Çizelge 4.1'de verilmiştir. Ölçümü yapılan sıvılar arasında saf sıvılar dışında sulu çözeltiler ve alkollü içkiler de bulunmaktadır. Alkol-su çözeltilerinden %70 alkol oranına sahip sıvılar tehlikeli olarak kabul edilmektedir (Tan vd., 2017). Sıvıların s-parametresi ölçüm grafikleri Şekil 4.2'de ve Şekil 4.3'de verilmiştir. Ölçümü yapılan bütün sıvılar pet şişelerde ve oda sıcaklığındadır. Ölçüm yapılırken şişe ile anten arasında yaklaşık 5mm kadar mesafe bırakılarak yapılmıştır. Ölçüm frekans aralığı 1,42-1,54 GHz 'dir.



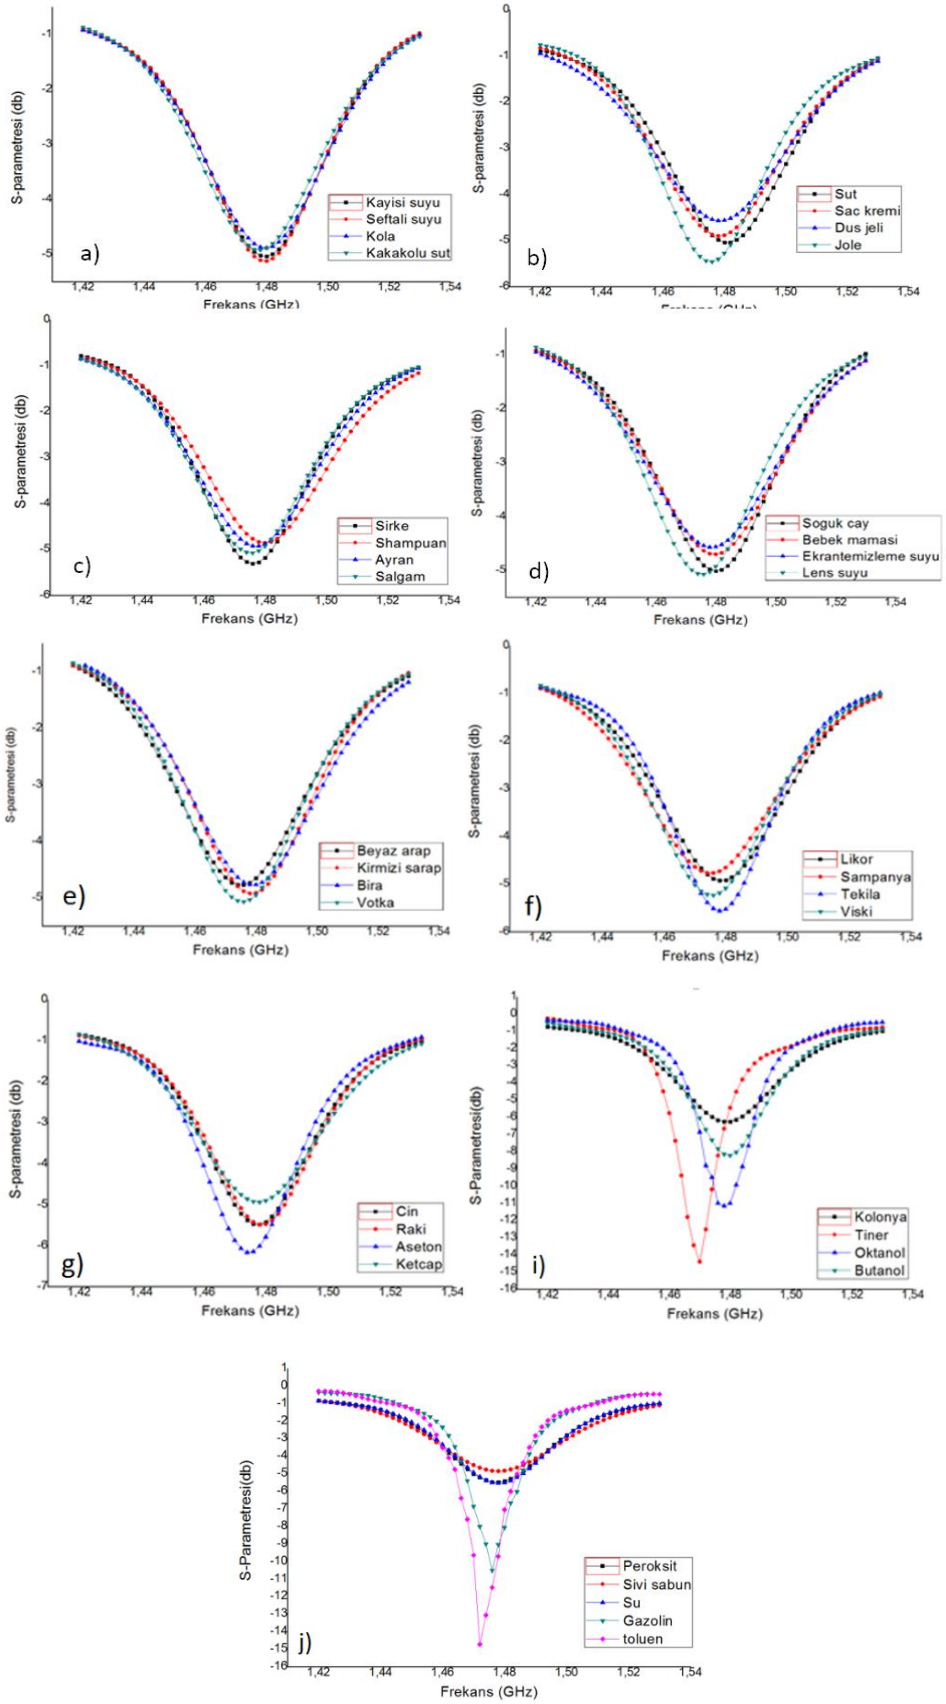
Şekil 4.1. Ölçüm seti.

Çizelge 4.1. Ölçümlerde kullanılan sıvılar.

Tehlikesiz Sıvılar			**Tehlikeli Sıvılar**
Su	Kırmızı şarap	Rakı	Etanol(%70,80,90,100)
Cin	Kayısı suyu	Lens suyu	Metanol (%70,80,90,100)
Süt	Ekran temizleme sıvısı	Beyaz şarap	1-Propanol (%70,80,90,100)
Bira	Soğuk çay	Şampuan	İsopropanol (%70,80,90,100)
Jöle	Şeftali suyu	Kakaolu süt	Tiner
Kola	Bebek maması	Şampanya	Kolonya
Sirke	Sıvı sabun	Viski	Oktanol
Tekila	Metanol (%10,20,…%60)	Duş jeli	Butanol
Votka	Etanol(%10,20,…%60)	Şalgam	Toluen
Ketçap	1-Propanol (%10,20,…%60)	Likör	Gazolin
Ayran	İsopropanol(%10,20,…%60)	Saç kremi	Peroksit
			Aseton



Şekil 4.2. Alkol-su çözeltilerinin s-parametre ölçümleri a)Etanol b)Metanol c)1-Propanol d)İsopropanol.



Şekil 4.3. Sıvıların s-parametresi ölçümleri.

4.1.1 Tehlikeli Sıvı Tespitinde Algoritmaların Performansının Değerlendirilmesi

Sıvıların sınıflandırılmasında 7 farklı algoritma kullanılmıştır. Algoritmaların sınıflandırmadaki model performanslarını değerlendirmek için her bir algoritmaya ait hata matrisleri oluşturulmuştur. Hata matrislerinde köşegen elemanlar doğru tahmin edilen sıvı sayılarını, diğer elemanlar ise yanlış tahmin edilen sıvı sayılarını göstermektedir. Kullanılan sınıflandırma algoritmaları ve hata matrisleri tablolar halinde verilmiştir.

4.1.1.1 Naive Bayes Algoritması ile Tehlikeli Sıvı Tespiti

Naive Bayes algoritmasının hata matrisi Çizelge 4.2'de verilmiştir. Bu matris incelendiğinde, Tüm eğitim setinin kullanılarak yapılan sınıflandırmada 24 tane tehlikeli sıvıdan 17 tanesini doğru, 7 tanesini yanlış tahmin etmiştir. 53 tane tehlikesiz sıvıdan 51 tanesini doğru 2 tanesini yanlış tahmin etmiştir. Çapraz doğrulamada ise doğru tahmin ettiği tehlikesiz sıvı sayısı aynı kalırken tehlikeli sıvılardan 8 tanesini yanlış tahmin etmiştir.

Çizelge 4.2. Naive Bayes algoritmasının hata matrisi.

Eğitim veri seti				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	17	7	24
	Tehlikesiz	2	51	53
	Toplam	19	58	77
10 Kat Çapraz Doğrulama				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	16	8	24
	Tehlikesiz	2	51	53
	Toplam	19	58	77

4.1.1.2 DDA Algoritması ile Tehlikeli Sıvı Tespiti

DDA kullanıldığında elde edilen hata matrisi Çizelge 4.3'de verilmiştir. Tüm eğitim verisinin kullanılmasında 77 sıvıdan 69 tanesini doğru tahmin ederken çapraz doğrulamada bu sayı 64'e düşmüştür. Algoritma tüm eğitim setinin kullanılarak yapılan

sınıflandırmada 24 tane tehlikeli sıvıdan 18 tanesini doğru, 6 tanesini yanlış tahmin etmiştir. 53 tane tehlikesiz sıvıdan 51 tanesini doğru 2 tanesini yanlış tahmin etmiştir. Çapraz doğrulama yapıldığında tehlikeli sıvılardan yanlış tahmin edilen sıvı sayısı 9'a tehlikesiz sıvılardan yanlış tahmin edilen sıvı sayısı ise 4'e yükselmiştir.

Çizelge 4.3. DDA algoritmasının hata matrisi.

Eğitim veri seti				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	18	6	24
	Tehlikesiz	2	51	53
	Toplam	19	57	77
10 Kat Çapraz Doğrulama				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	15	9	24
	Tehlikesiz	4	49	53
	Toplam	19	58	77

4.1.1.3 KDA Algoritması ile Tehlikeli Sıvı Tespiti

KDA algoritması kullanılarak elde edilen hata matrisi Çizelge 4.4'de verilmiştir.

Çizelge 4.4. KDA algoritmasının hata matrisi.

Eğitim veri seti				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	17	7	24
	Tehlikesiz	0	53	53
	Toplam	17	60	77
10 Kat Çapraz Doğrulama				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	16	8	24
	Tehlikesiz	2	51	53
	Toplam	16	61	77

KDA algoritması eğitimde bütün tehlikesiz sıvıları doğru tahmin etme başarısını gösterse de çapraz doğrulamada aynı başarıyı gösterememiştir. Algoritmanın çapraz doğrulamada doğru tahmin ettiği tehlikesiz sıvı sayısı 51 dir. Tehlikeli sıvı tespitinde eğitimde 7 çapraz doğrulamada 8 tane sıvıyı yanlış tahmin etmiştir.

4.1.1.4 DVM Algoritması ile Tehlikeli Sıvı Tespiti

DVM algoritması kullanıldığında elde edilen hata matrisi Çizelge 4.5'de verilmiştir. Burada algoritmanın hem eğitimde hem de çapraz doğrulamada tehlikeli sıvıdan hiç birini doğru tespit edemediği görülmektedir. Tehlikeli sıvı tespitinde başarısız olan algoritma bütün sıvıları tehlikesiz olarak tahmin etmiştir. Çizelge 4.5'de verilen hata matrisi Sigmoid çekirdek fonksiyonu kullanılarak elde edilmiştir.

Çizelge 4.5. DVM algoritmasının hata matrisi.

Eğitim veri seti				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	0	24	24
	Tehlikesiz	0	53	53
	Toplam	18	59	77
10 Kat Çapraz Doğrulama				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	0	24	24
	Tehlikesiz	0	53	53
	Toplam	18	59	77

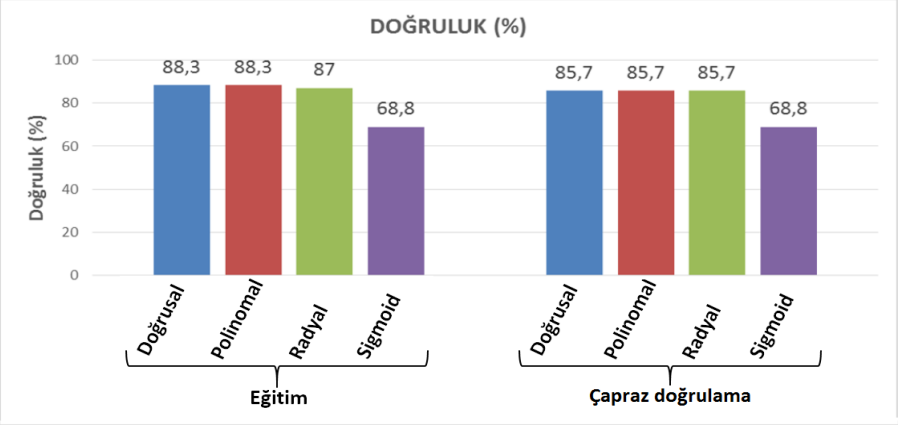
4.1.1.4.1 DVM Algoritmasında Farklı Çekirdek fonksiyon Kullanımı

DVM algoritması ile yapılan sınıflandırma da kullanılan çekirdek fonksiyon seçimi önemlidir. Doğru seçilmemiş bir fonksiyon sınıflandırmanın başarısını azaltabileceği gibi doğru seçilen bir fonksiyon da sınıflandırma başarısını arttıracaktır. Çekirdek fonksiyonunun mikrodalga verilerinden tehlikeli sıvı belirlemeye etkisini araştırmak için 4 farklı çekirdek fonksiyon kullanılmıştır. Kullanılan çekirdek fonksiyonlara ait hata matrisleri Çizelge 4.6'de verilmiştir.

Çizelge 4.6. DVM ile farklı çekirdek fonksiyonlarının hata matrisi.

			Tahmin edilen sınıf			
			Eğitim veri seti		10 Kat Çapraz Doğrulama	
Gerçek sınıf	Doğrusal		Tehlikeli	Tehlikesiz	Tehlikeli	Tehlikesiz
		Tehlikeli	17	7	15	9
		Tehlikesiz	2	51	2	51
	Polinomal		Tehlikeli	Tehlikesiz	Tehlikeli	Tehlikesiz
		Tehlikeli	17	7	15	9
		Tehlikesiz	2	51	2	51
	Radyal temel		Tehlikeli	Tehlikesiz	Tehlikeli	Tehlikesiz
		Tehlikeli	16	8	16	8
		Tehlikesiz	2	51	3	50
	Sigmoid		Tehlikeli	Tehlikesiz	Tehlikeli	Tehlikesiz
		Tehlikeli	0	24	0	24
		Tehlikesiz	0	53	0	53

Çekirdek fonksiyon kullanımının sınıflandırma başarısına etkisini anlamak için hem tüm eğitim seti kullanılarak hem de çapraz doğrulamadan elde edilen hata matrisleri karşılaştırılmıştır. Tabloda görüldüğü gibi sınıflandırmada farklı fonksiyon kullanımı doğru tahmin edilen sıvı sayısında değişikliklere neden olmuştur. En yüksek doğru tahmin edilen sıvı sayısına Doğrusal ve Polinomal fonksiyonlarının kullanımı ile ulaşılmıştır. En düşük doğru tahmin sayısı da Sigmoid fonksiyonu kullanılarak yapılan sınıflandırma sonucu elde edilmiştir. Doğrusal ve Polinomal, Radyal temel ve Sigmoid fonksiyonunun sınıflandırmadaki doğruluk yüzdelerini gösteren grafik Şekil 4.4'de verilmiştir.



Şekil 4.4. Farklı fonksiyonlarla DVM algoritmasının tehlikeli sıvı bulmadaki doğruluk oranları.

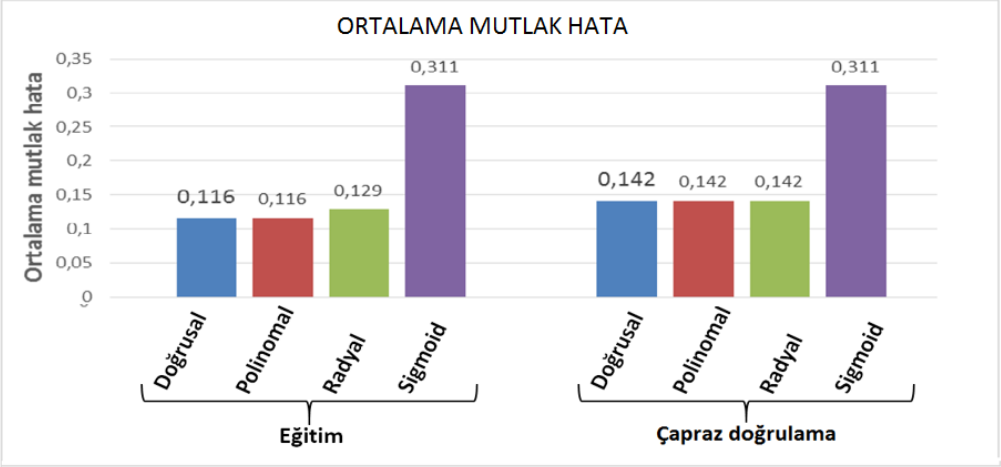
Grafiktan de anlaşılacağı gibi en yüksek doğruluk oranı eğitimde %88,3 çapraz doğrulamada %85,7 dir ve bu değerler Doğrusal ve Polinomal fonksiyon kullanılması sonucu elde edilmiştir. Sigmoid fonksiyonu kullanımı ile algoritmanın doğruluk oranı %68,8 iken Doğrusal yada Polinomal fonksiyon kullanımı ile %88,3'e çıkarılabileceği görülmektedir. Çekirdek fonksiyonlarının performans karşılaştırmasında duyarlılık, hassasiyet, F-skoru ve kappa istatistik değerler de incelenmiştir. Bu değerler Çizelge 4.7'de gösterilmiştir.

Çizelge 4.7. Farklı fonksiyon kullanımı ile DVM algoritmasının tehlikeli sıvı bulmadaki performans ölçütleri.

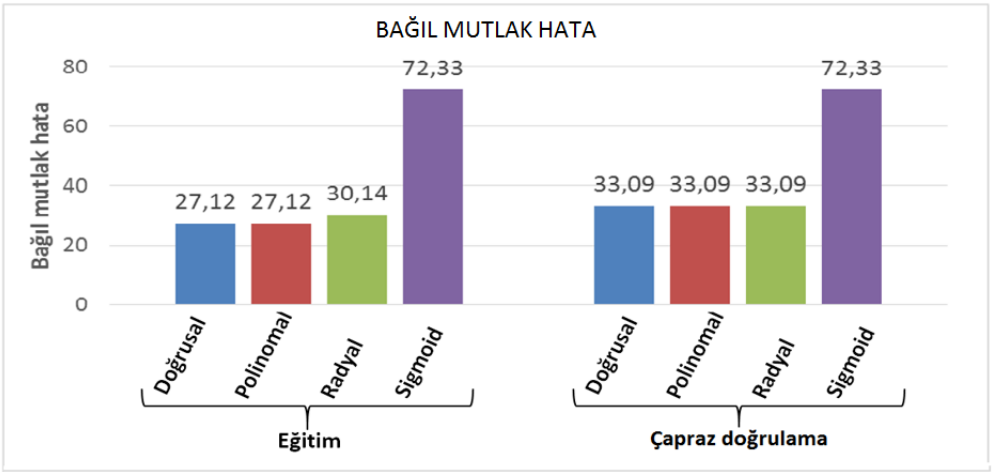
		Doğrusal	Polinomal	Radyal Temel	Sigmoid
Eğitim	Duyarlılık	0,88	0,88	0,87	--
	Hassasiyet	0,88	0,88	0,87	0,68
	F-skoru	0,87	0,87	0,86	--
	Kappa	0,71	0,71	0,67	0
Çapraz doğrulama	Duyarlılık	0,86	0,86	0,85	--
	Hassasiyet	0,85	0,85	0,85	0,68
	F-skoru	0,84	0,84	0,85	--
	Kappa	0,63	0,63	0,64	0

Sigmoid fonksiyonunda tehlikeli sıvıların hiçbirini doğru tahmin edemediğinden duyarlılık ve F-skoru hesaplanamamıştır. En iyi sonuçlar Doğrusal ve Polinomal fonksiyon ile elde edilmiştir. Bu fonksiyonların eğitim ve çapraz doğrulamada elde edilen

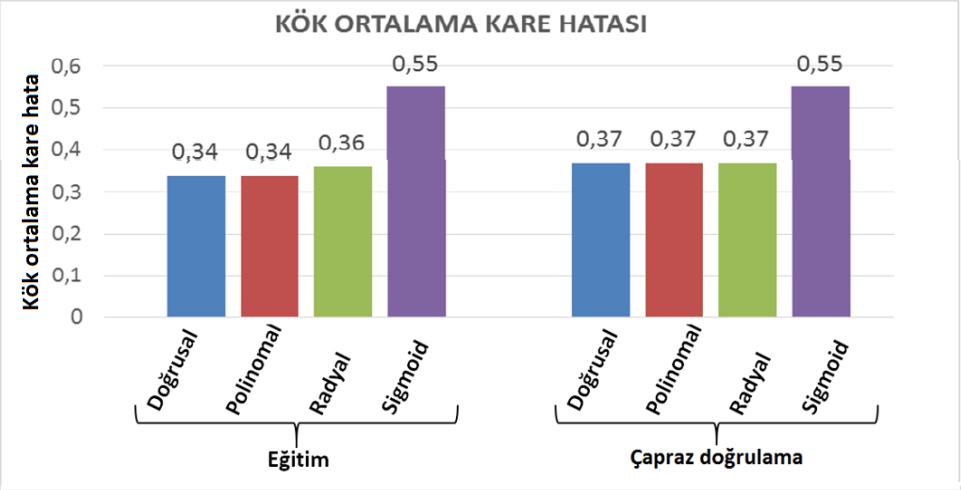
hata değerleri de karşılaştırılmıştır. Hata ölçütü olarak kullanılan birçok hata değeri ölçütü mevcuttur. Sıklıkla kullanılan hata değerleri bu tez kapsamında incelenmiştir. Farklı fonksiyonlarla DVM algoritması ile sınıflandırmadan elde edilen OMH değerleri Şekil 4.5'te, BMH değerleri Şekil 4.6'te, KOKH değerleri Şekil 4.7'te ve KBKH değerleri Şekil 4.8'te verilmiştir.



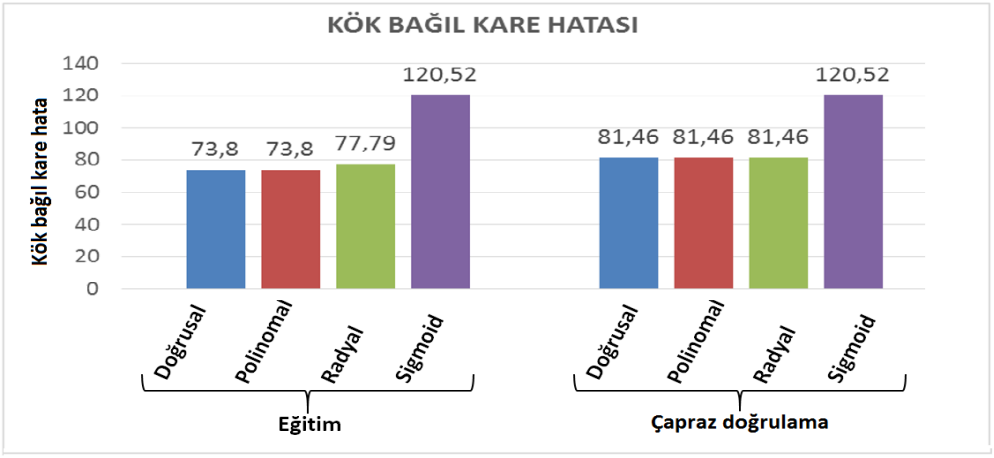
Şekil 4.5. Farklı fonksiyonlarla DVM algoritmasının ortalama mutlak hatası.



Şekil 4.6. Farklı fonksiyonlarla DVM algoritmasının bağıl mutlak hatası.



Şekil 4.7. Farklı fonksiyonlarla DVM algoritmasının kök ortalama kare hatası.



Şekil 4.8. Farklı fonksiyonlarla DVM algoritmasının kök bağıl kare hatası.

Bütün hata ölçütleri incelendiğinde çapraz doğrulamada elde edilen hata değerlerin eğitim verisinin sınıflandırılmasından elde edilen hata değerlerinden fazla çıktığı görülmüştür. Hata değerleri de diğer performans ölçütlerini destekler niteliktedir. En az hata oranı Doğrusal ve Polinomal fonksiyon ile elde edilmişken en fazla hata oranı Sigmoid fonksiyonu kullanımı ile elde edilmiştir.

4.1.1.5 SMO Algoritması ile Tehlikeli Sıvı Tespiti

SMO algoritması DVM algoritmasına yakın sonuçlar vermiştir. Algoritmanın sınıflandırma performansının incelendiği hata matrisi Çizelge 4.8'de verilmiştir. Bu tabloya göre algoritmanın doğru tahmin ettiği sıvı sayısı toplam 67'dir.

Çizelge 4.8. SMO algoritmasının hata matrisi.

Eğitim veri seti				
		Tahmin edilen sınıf		
Gerçek sınıf		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	16	8	24
	Tehlikesiz	2	51	53
	Toplam	18	59	77
10 Kat Çapraz Doğrulama				
		Tahmin edilen sınıf		
Gerçek sınıf		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	16	8	24
	Tehlikesiz	2	51	53
	Toplam	18	59	77

4.1.1.6 K-EYK Algoritması ile Tehlikeli Sıvı Tespiti

Tehlikeli sıvı tespitinde K-EYK algoritması oldukça iyi sonuçlar vermiştir. K değeri 1 olarak alınıp uzaklık ölçütlerinden Öklid mesafesi kullanılarak yapılan sınıflandırmadan elde edilen hata matrisi Çizelge 4.9'da verilmiştir.

Çizelge 4.9. K-EYK algoritmasının hata matrisi.

Eğitim veri seti				
		Tahmin edilen sınıf		
Gerçek sınıf		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	24	0	24
	Tehlikesiz	1	52	53
	Toplam	25	52	77
10 Kat Çapraz Doğrulama				
		Tahmin edilen sınıf		
Gerçek sınıf		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	19	5	24
	Tehlikesiz	4	49	53
	Toplam	23	54	77

Hata matrisine bakıldığında eğitimde bütün tehlikeli sıvıları tespit edebildiği görülmüştür. Çapraz doğrulamada ise doğru tespit edilen tehlikeli sıvı sayısı 19' a düşmektedir. Tehlikesiz sıvıların tespitinde ise algoritma eğitimde 1 sıvıyı sadece yanlış tahmin ederken çapraz doğrulamada bu sayı 4' e çıkmıştır.

4.1.1.6.1 K-EYK Algoritma Parametrelerinin Sınıflandırma Performansına Etkisi

Bu algoritma kullanılırken verinin en iyi şekilde sınıflandırılabilmesi için algoritmaya ait bazı parametrelerin doğru belirlenmesi gerekir. Algoritmanın başarısını etkileyen bu parametreler uzaklık ölçütleri, komşu sayısı (*k*) ve ağırlıklandırma uygulamasıdır. Mikrodalga verilerinden tehlikeli sıvı tespitine bu parametrelerin nasıl bir etki yapacağını incelemek için 4 farklı uzaklık ölçütü ve 10 farklı k değeri kullanılmıştır. Kullanılan uzaklık ölçütleri Öklid, Chebyshev, Manhattan ve Minkowski uzaklık ölçütleridir. *K* değeri için 1 den 10'a kadar değişen değerler kullanılmıştır. Her uzaklık ölçütü için *k* değeri 1-10 arasında değiştirilerek sınıflandırma yapılmış ve sınıflandırma sonucu elde edilen hata matrisleri ayrı ayrı verilmiştir. Parametrelerin hem tüm eğitim setinin kullanılarak yapılan sınıflandırmaya hem de çapraz doğrulama ile yapılan sınıflandırmaya etkileri incelenmiştir. Bütün eğitim setinin kullanıldığı sınıflandırmada Öklid uzaklık ölçütüne ait hata matrisi Çizelge 4.10'da verilmiştir.

Çizelge 4.10. Eğitimde Öklid uzaklığının hata matrisi.

k:1				*k*:2			*k*:3			*k*:4			*k*:5		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	24	0	DP	23	1	DP	18	6	DP	19	5	DP	18	6
	DN	1	52	DN	5	48	DN	2	51	DN	3	50	DN	3	50
k:6				*k*:7			*k*:8			*k*:9			*k*:10		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	19	5	DP	18	6	DP	19	5	DP	16	8	DP	16	8
	DN	4	49	DN	1	52	DN	3	50	DN	2	51	DN	2	51

Öklid uzaklığı kullanıldığında *k:*1 değeri için 24 tane tehlikeli sıvının hepsi doğru sınıflandırılmış ve sadece 1 tehlikesiz sıvı yanlış sınıflandırılmıştır. Doğru sınıflandırılan sıvı sayısı *k* değerinin artmasıyla azalış göstermiştir. En yüksek yanlış sınıflandırılan sıvı

sayısı 10 dur. Bu sonuç *k* değerinin 10 seçilmesi ile elde edilmiştir. Chebyshev uzaklık ölçütü kullanımı ile elde edilen hata matrisi Çizelge 4.11'de verilmiştir.

Çizelge 4.11. Eğitimde Chebyshev uzaklığının hata matrisi.

k:1				*k*:2			*k*:3			*k*:4			*k*:5		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	24	0	DP	24	0	DP	17	7	DP	18	6	DP	18	6
	DN	1	52	DN	6	47	DN	3	50	DN	5	48	DN	4	49
k:6				*k*:7			*k*:8			*k*:9			*k*:10		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	19	5	DP	18	6	DP	19	5	DP	15	9	DP	15	9
	DN	5	48	DN	1	52	DN	3	50	DN	2	51	DN	3	50

Bu uzaklık ölçütü kullanıldığında *k*:1 için yine aynı doğru tahmin sayısına elde edilirken *k*:10 değeri için yanlış tahmin sayısı 12 olmuştur. Manhattan uzaklık ölçütü için elde edilen hata matrisi Çizelge 4.12'de verilmiştir.

Çizelge 4.12. Eğitimde Manhattan uzaklığının hata matrisi.

k:1				*k*:2			*k*:3			*k*:4			*k*:5		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	24	0	DP	23	1	DP	18	6	DP	19	5	DP	19	5
	DN	1	52	DN	6	47	DN	2	51	DN	3	50	DN	3	50
k:6				*k*:7			*k*:8			*k*:9			*k*:10		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	19	5	DP	18	6	DP	19	5	DP	16	8	DP	16	8
	DN	5	48	DN	1	52	DN	3	50	DN	2	51	DN	2	51

Bu tablo incelendiğinde Öklid uzaklığında olduğu gibi en az yanlış tahmin sayısı 1, en fazla yanlış tahmin sayısının 10 olduğu görülmektedir. Minkowski uzaklığının hata matrisi Çizelge 4.13'de gösterilmiştir.

Çizelge 4.13. Eğitimde Minkowski uzaklığının hata matrisi.

k:1				*k*:2			*k*:3			*k*:4			*k*:5		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	24	0	DP	23	1	DP	18	6	DP	19	5	DP	18	6
	DN	1	52	DN	5	48	DN	2	51	DN	3	50	DN	3	50
k:6				*k*:7			*k*:8			*k*:9			*k*:10		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	19	5	DP	18	6	DP	19	5	DP	16	8	DP	16	8
	DN	4	49	DN	1	52	DN	3	50	DN	2	51	DN	2	51

Bu uzaklık ölçütünde de *k* değerinin artması ile doğru tahmin sayısında bir azalım görülmüştür. En fazla doğru sayısı *k*:1 için elde edilirken en az doğru sayısı *k*:10 için elde edilmiştir. Eğitim için yapılanlar çapraz doğrulama için de tekrar edilerek uzaklık ölçütlerinin ve *k* sayısının algoritmanın başarısına etkisi incelenmiştir. Öklid uzaklığının hata matrisi Çizelge 4.14'de verilmiştir.

Çizelge 4.14. Çapraz Doğrulamada Öklid uzaklığının hata matrisi.

k:1				*k*:2			*k*:3			*k*:4			*k*:5		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	16	8	DP	18	6	DP	14	10	DP	18	6	DP	18	6
	DN	7	46	DN	11	42	DN	3	50	DN	5	48	DN	4	49
k:6				*k*:7			*k*:8			*k*:9			*k*:10		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	18	6	DP	16	8	DP	16	8	DP	16	8	DP	16	8
	DN	5	48	DN	4	49	DN	4	49	DN	2	51	DN	5	48

En yüksek doğru sınıflandırılan sıvı sayısı *k*:5, 6 ve 9 değerinde görülürken en düşük doğru sınıflandırılan sıvı sayısı *k*:2 değerinde görülmüştür. Algoritma *k*:5, 6 ve 9 değerinde 10 tane sıvıyı yanlış sınıflandırırken *k*:2 değerinde 17 tane sıvıyı yanlış sınıflandırmıştır. Chebyshev uzaklığının çapraz doğrulamada ile elde edilen hata matrisi Çizelge 4.15'de verilmiştir.

Çizelge 4.15. Çapraz doğrulamada Chebyshev uzaklığının hata matrisi.

k:1				*k*:2			*k*:3			*k*:4			*k*:5		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	16	8	DP	18	6	DP	15	9	DP	17	7	DP	17	7
	DN	8	45	DN	11	42	DN	5	48	DN	6	47	DN	5	48
k:6				*k*:7			*k*:8			*k*:9			*k*:10		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	17	7	DP	14	10	DP	14	10	DP	14	10	DP	14	10
	DN	5	48	DN	2	51	DN	4	49	DN	2	51	DN	3	50

Tehlikeli sıvıların bulunmasında Chebyshev uzaklığı kullanıldığında da en yüksek yanlış tahmin edilen sıvı sayısı *k*:2 değerini aldığında elde edilmiştir. Algoritma *k*:2 değerinde 60 tane sıvıyı doğru tahmin etmiştir. *K*: 5, 6, 7 ve 8 değerini aldığında algoritma 65 tane sıvıyı doğru tahmin ederek en yüksek doğru sıvı tahminine ulaşmıştır. Manhattan uzaklığının kullanımının sınıflandırma performansını gösteren hata matrisi Çizelge 4.16'de verilmiştir.

Çizelge 4.16. Çapraz doğrulamada Manhattan uzaklığının hata matrisi.

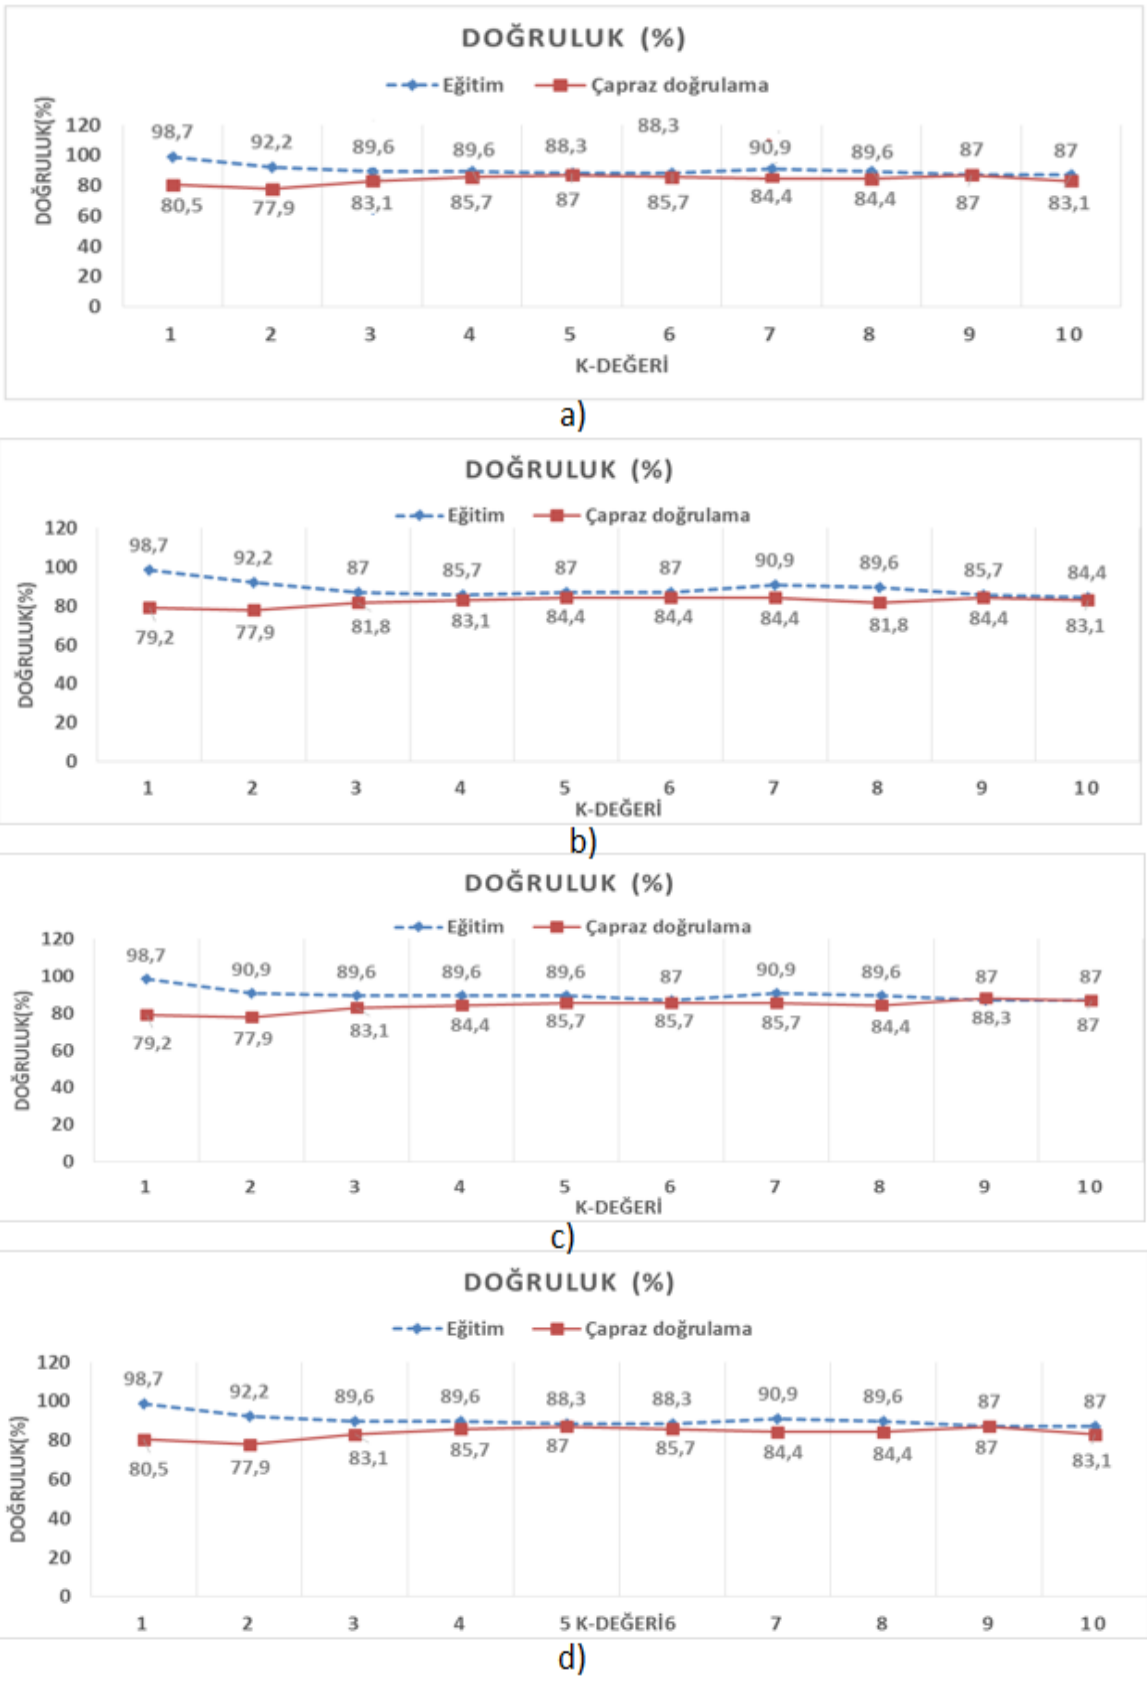
k:1				*k*:2			*k*:3			*k*:4			*k*:5		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	16	8	DP	18	6	DP	15	9	DP	19	5	DP	17	7
	DN	8	45	DN	11	42	DN	4	49	DN	7	46	DN	4	49
k:6				*k*:7			*k*:8			*k*:9			*k*:10		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	18	6	DP	16	8	DP	16	8	DP	16	8	DP	16	8
	DN	5	48	DN	3	50	DN	4	49	DN	1	52	DN	2	51

Bu uzaklık ölçütünde *k*:9 değeri için en yüksek doğru tahmin edilen sıvı sayısına ulaşılmıştır. *K*:2 değeri için yine algoritma en düşük doğru sıvı sayısı tahminine sahiptir. Minkowski uzaklık ölçütü kullanımında algoritmanın doğru ve yanlış tahmin ettiği sıvıları gösteren hata matrisi Çizelge 4.17'de verilmiştir.

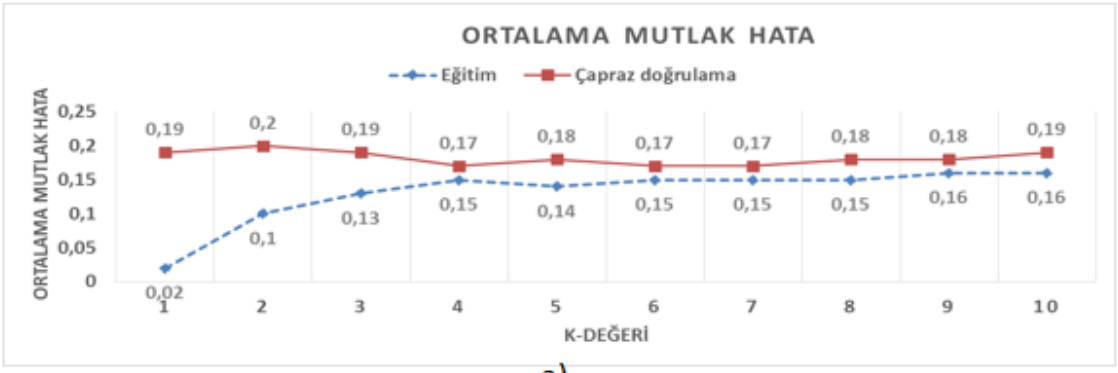
Çizelge 4.17. Çapraz doğrulamada Minkowski uzaklığının hata matrisi.

k:1				*k*:2			*k*:3			*k*:4			*k*:5		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	16	8	DP	18	6	DP	14	10	DP	18	6	DP	18	6
	DN	7	46	DN	11	42	DN	3	50	DN	5	48	DN	4	49
k:6				*k*:7			*k*:8			*k*:9			*k*:10		
	Gerçek														
Tahmin		DP	DN		DP	DN		DP	DN		DP	DN		DP	DN
	DP	18	6	DP	16	8	DP	16	8	DP	16	8	DP	16	8
	DN	5	48	DN	4	49	DN	4	49	DN	2	51	DN	5	48

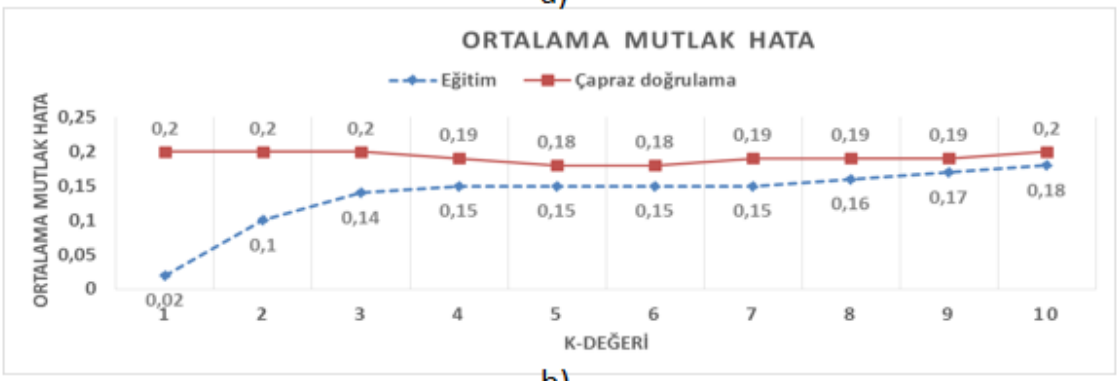
Çizelge 4.18 görüldüğü gibi doğru tahmin edilen en yüksek değere *k*:5,9 alındığında ulaşılmıştır. En düşük doğru tahmin sayısı *k*:2 alındığında elde edilmiştir. Doğruluk oranları incelemek için yine farklı uzaklık ölçütleri kullanılarak k değeri 1 ile 10 arasında değiştirilmiştir. Yapılan sınıflandırmalardan elde edilen doğruluk yüzdelerini gösteren grafikler Şekil 4.9'da verilmiştir. Şekil incelendiğinde hem eğitim verisinin sınıflandırılmasında hem de çapraz doğrulama ile yapılan sınıflandırmada en yüksek doğruluk değeri *k*:1 seçildiğinde elde edildiği ve bu değerin *k* değerinin artması ile azaldığı görülmektedir. *K*:1 için eğitim verisinin sınıflandırılmasında elde edilen doğruluk değeri tüm uzaklık ölçütlerinde %98,7'tür. Çapraz doğrulama da ise Öklid ve Minkowski uzaklık ölçütlerinde %80,5, Chebyshev ve Manhattan uzaklık ölçütlerinde %79,2'dir. Algoritmanın hata ölçütlerindeki değişim incelendiğinde tüm hata ölçütlerinde eğitimde k değerinin artması ile hata oranı artmakta çapraz doğrulamada ise *k* değerinin artması ile hata oranını azaldığı görülmektedir. Uzaklık ölçütleri ve *k* değerinin etkilerinin incelendiği ortalama mutlak hata Şekil 4.10 'da, kök ortalama kare Şekil 4.11'de, bağıl mutlak kare hata Şekil 4.12'de ve kök bağıl kare hata grafikleri Şekil 4.13'de verilmiştir.



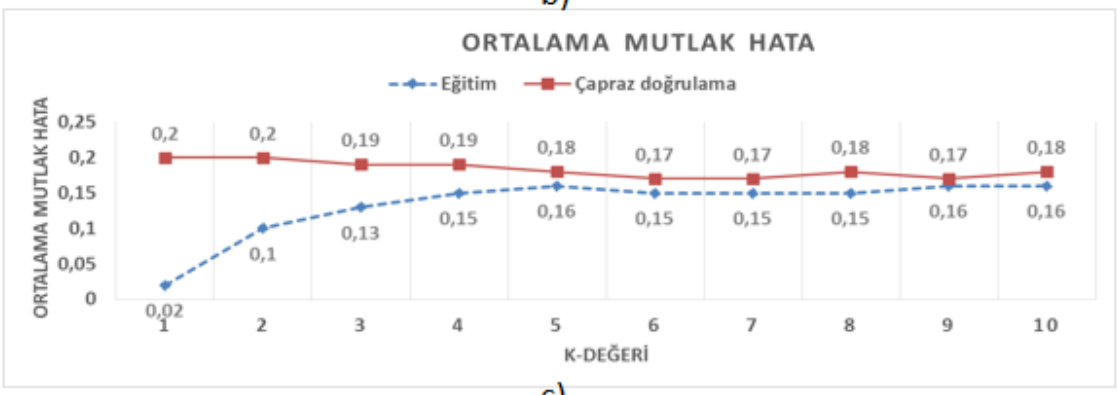
Şekil 4.9. Doğruluk oranı değişimi a)Öklid b)Chebyshev c)Manhattan d)Minkowski.



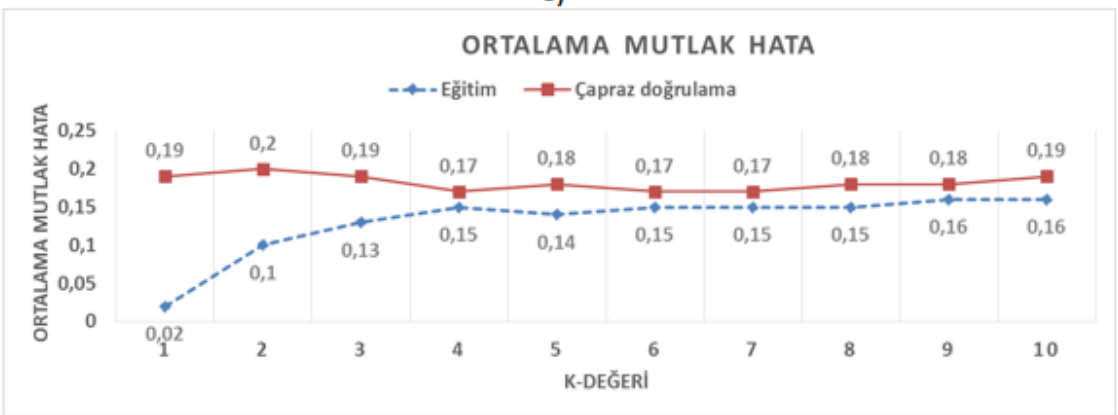
a)



b)

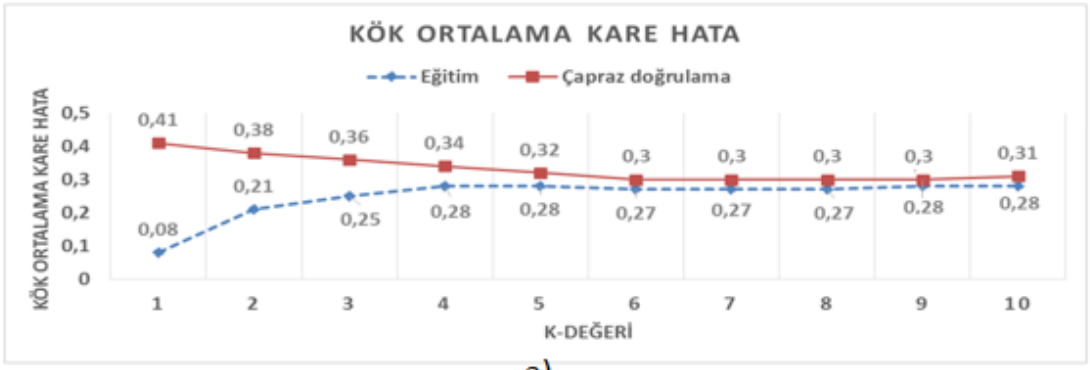


c)

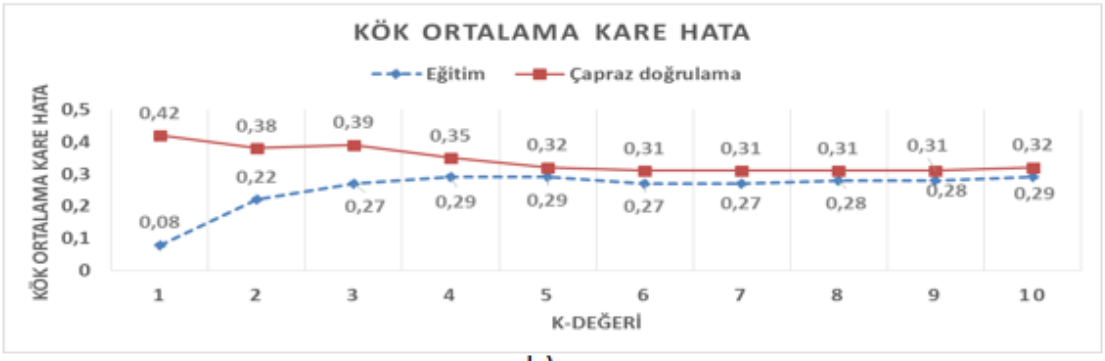


d)

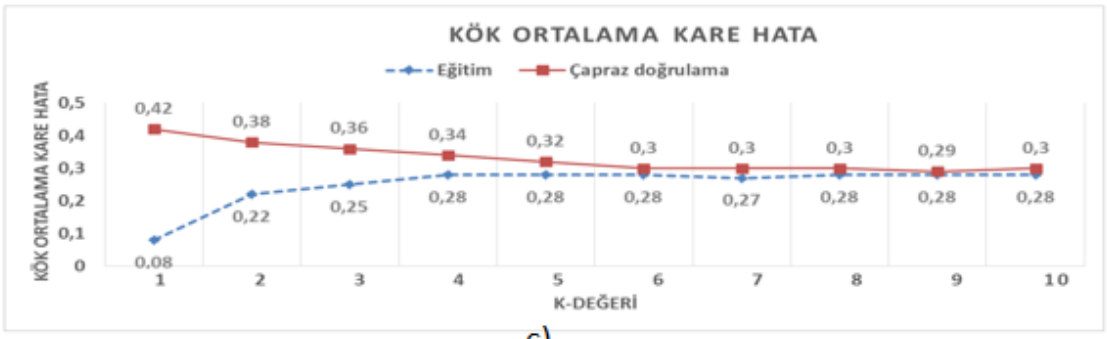
Şekil 4.10. Ortalama mutlak hata a) Öklid, b) Chebyshev, c) Manhattan, d) Minkowski.



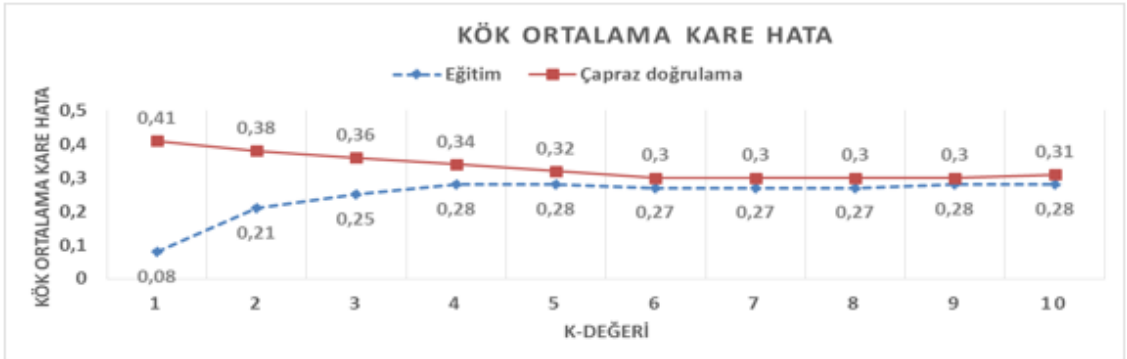
a)



b)

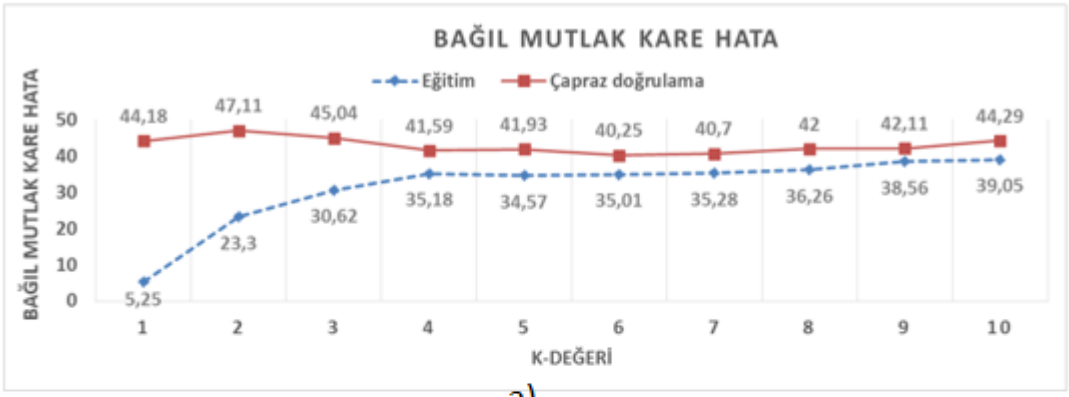


c)



d)

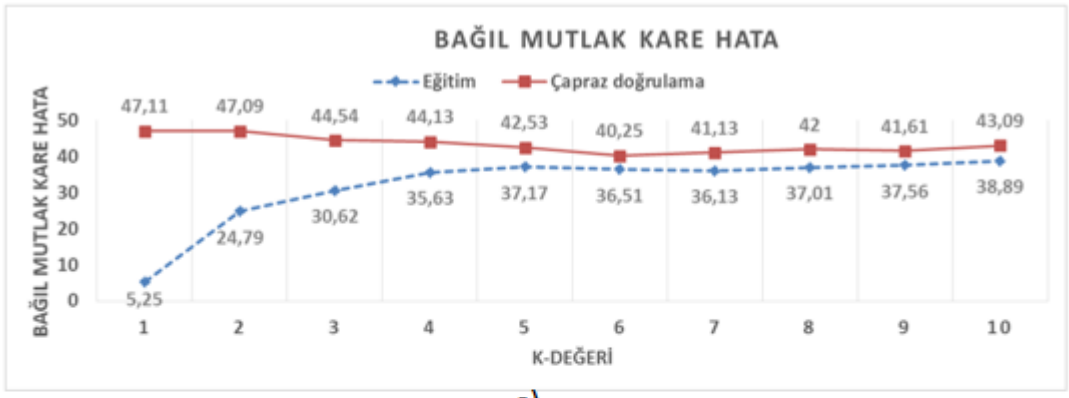
Şekil 4.11. Kök ortalama kare hata a) Öklid, b) Chebyshev, c) Manhattan, d) Minkowski.



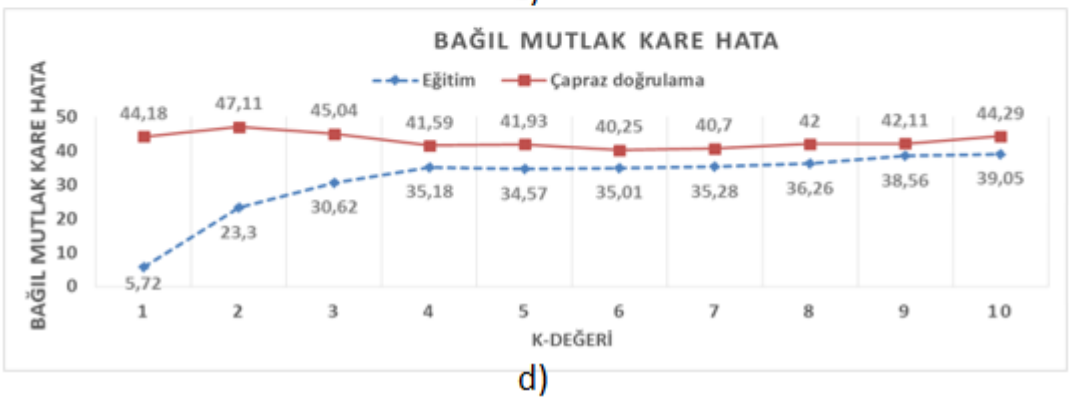
a)



b)

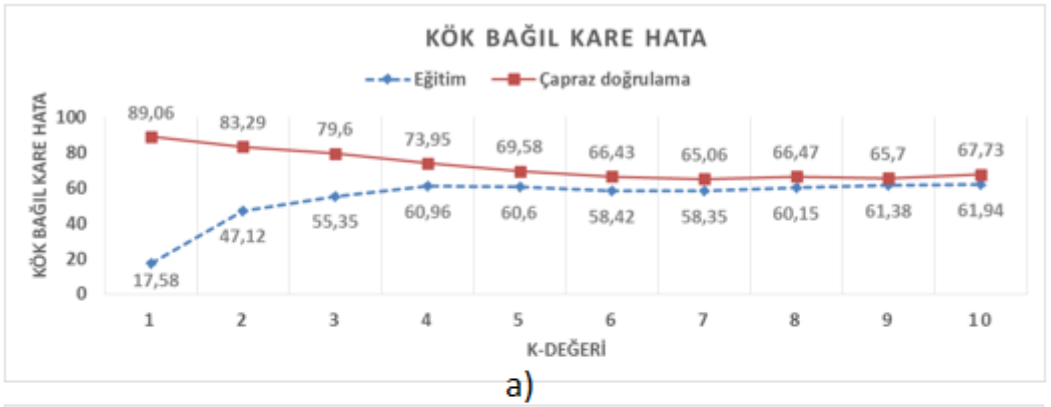


c)

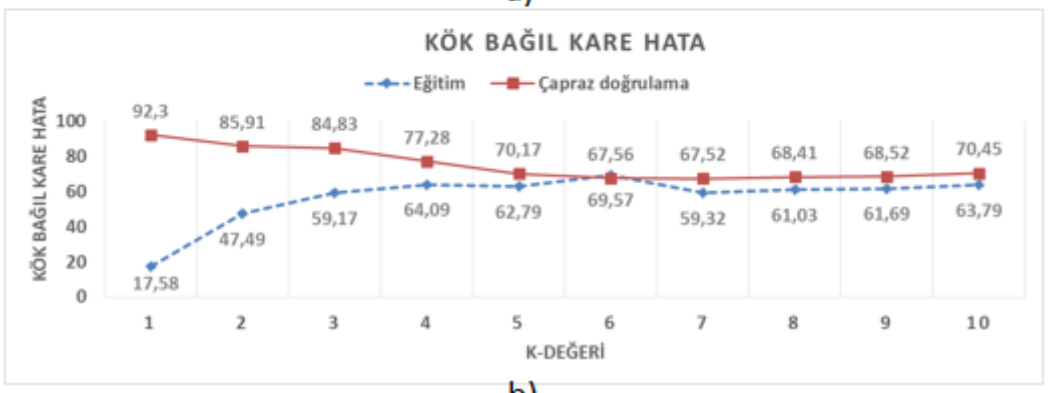


d)

Şekil 4.12. Bağıl mutlak kare hata a) Öklid, b) Chebyshev, c) Manhattan, d) Minkowski.



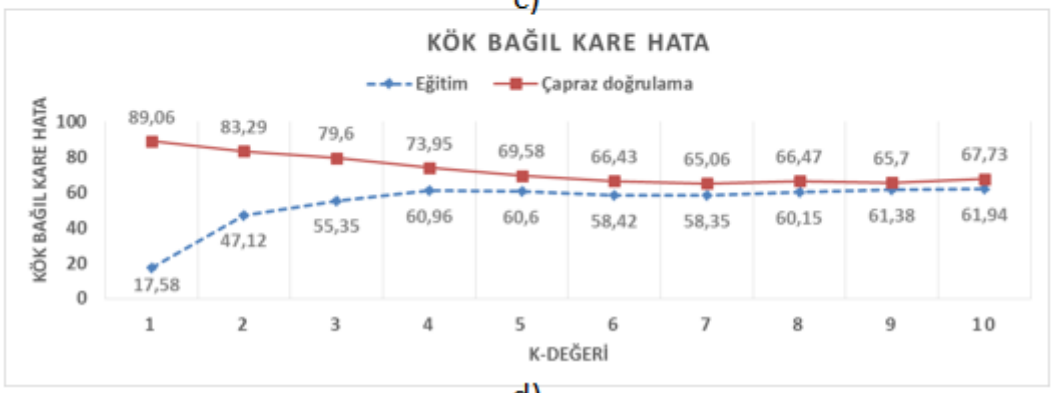
a)



b)



c)



d)

Şekil 4.13. Kök bağıl hata a) Öklid, b) Chebyshev, c) Manhattan, d) Minkowski.

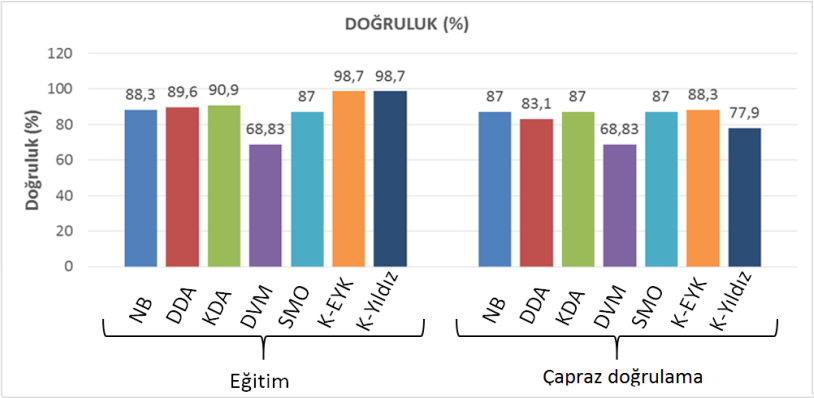
4.1.1.7 K-Yıldız Algoritması ile Tehlikeli Sıvı Tespiti

K-Yıldız algoritması ile yapılan tehlikeli sıvı tespiti de K-EYK algoritması gibi iyi sonuçlar vermiştir. Çizelge 4.18'de verilen hata matrisi incelendiğinde eğitimde tehlikeli sıvılardan sadece 1 tanesini tehlikesiz sıvı olarak tahmin ettiği tehlikesiz sıvıların tamamını doğru tahmin ettiği görülmektedir. Çapraz doğrulamada yapıldığında ise algoritmanın doğru tahmin ettiği sayılarda bir azalım görülmektedir. 24 tane tehlikeli sıvıdan 10 tanesini yanlış, 53 tane tehlikesiz sıvıdan da 7 tane sıvıyı yanlış tahmin etmiştir.

Çizelge 4.19. K-Yıldız algoritmasının hata matrisi.

Eğitim veri seti				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	23	1	24
	Tehlikesiz	0	53	53
	Toplam	23	54	77
10 Kat Çapraz Doğrulama				
		Tahmin edilen sınıf		
Gerçek		Tehlikeli	Tehlikesiz	Toplam
	Tehlikeli	14	10	24
	Tehlikesiz	7	46	53
	Toplam	21	56	77

Kullanılan bütün algoritmaların hem eğitimde hem de çapraz doğrulamada elde ettikleri doğruluk değerlerini gösteren grafik Şekil 4.14' de verilmiştir.



Şekil 4.14. Algoritmaların tehlikeli sıvı bulmadaki doğruluk değerleri.

Algoritmaların doğruluk değerlerinin karşılaştırmak için grafik incelendiğinde eğitimde K-EYK ve K-Yıldız algoritmaları %98,7 değeri ile en yüksek doğruluk değerine sahip olduğu görülmektedir. Çapraz doğrulamada K-EYK algoritması yine en yüksek doğruluk değerini verirken K-Yıldız algoritması en düşük doğruluk değerine sahip olmuştur. Çapraz doğrulamada doğruluk değeri eğitimde elde edilen doğruluk değerinden daha düşüktür. SMO algoritması hem eğitimde hem de çapraz doğrulamada aynı doğruluk değerini gösteren tek algoritmadır. Algoritmaların performans değerlendirilmesinde kullanılan diğer ölçütler duyarlılık, hassasiyet, F-skoru ve Kappa istatistik değeridir. Her algoritmanın veriyi sınıflandırması sonucunda eğitim ve çapraz doğrulamada elde ettiği performans ölçütleri Çizelge 4.19'de verilmiştir.

Çizelge 4.20. Algoritmaların tehlikeli sıvı bulmadaki performans ölçütleri.

		NAIVE BAYES	DDA	KDA	DVM	SMO	K-EYK	K-YILDIZ
Eğitim	Duyarlılık	0,88	0,89	0,92	---	0,87	0,98	0,98
	Hassasiyet	0,88	0,89	0,90	0,68	0,87	0,98	0,98
	F-skoru	0,87	0,89	0,90	---	0,86	0,98	0,98
	Kappa	0,71	0,74	0,76	0	0,67	0,97	0,96
Çapraz doğrulama	Duyarlılık	0,87	0,82	0,87	---	0,87	0,88	0,77
	Hassasiyet	0,87	0,83	0,87	0,68	0,87	0,88	0,77
	F-skoru	0,86	0,82	0,86	---	0,86	0,87	0,77
	Kappa	0,67	0,58	0,67	0	0,67	0,71	0,46

Bir sınıflandırmada duyarlılık- hassasiyet, F-skoru ve kappa istatistik değerinin mümkün olduğunca 1'e yakın bir değer alması istenir. Bu değerler ne kadar 1'e yakın ise sınıflandırma o kadar başarılı olmuş demektir. Sonuçlara bakıldığında en yüksek hassasiyet, duyarlılık, F-skoru ve kappa değerleri eğitimde K-EYK ve K-yıldız algoritması ile elde edilmiştir. Çapraz doğrulama yapıldığında ise K-yıldız algoritmasın K-EYK algoritmasından daha düşük bir performans göstermiştir Çapraz doğrulamada da eğitimde olduğu gibi en başarılı algoritma K-EYK algoritması olmuştur. Hata değerleri algoritmanın sınıflandırmayı ne kadar doğrulukla yaptığını gösteren bir performans ölçütüdür. Bu tezde KOKH, OMH, BMH, KBKH olmak üzere 4 farklı hata ölçütü incelenmiştir. Sınıflandırma sonucunda hem eğitimde hem de çapraz doğrulamada elde edilen bu hata değerleri Çizelge 4.20'de gösterilmiştir. En fazla doğru tahminde bulunan sınıflandırma algoritması olan K-EYK algoritması eğitimde bütün hata ölçütlerinde en

düşük hata oranına sahip olduğu görülmektedir. Bu durum algoritmanın başarısının bir göstergesidir. Fakat çapraz doğrulamada bu oranlar biraz artış göstermiştir. Çapraz doğrulama da en düşük hata değerleri KDA algoritması tarafından elde edilmiştir. Eğitimde en yüksek hata oranları DVM algoritmasında görülmektedir.

Çizelge 4.21. Algoritmaların tehlikeli sıvı bulmadaki hata değerleri.

	Eğitim Veri Seti				10 Kat Çapraz Doğrulama			
	KOKH	OMH	BMH (%)	KBKH (%)	KOKH	OMH	BMH (%)	KBKH (%)
NAIVE BAYES	0,34	0,11	27,08	73,66	0,33	0,11	27,03	72,15
DDA	0,29	0,12	29,07	64,55	0,35	0,16	37,59	76,12
KDA	0,30	0,09	21,11	65,09	0,32	0,10	24,08	69,46
DVM	0,55	0,31	72,33	120,33	0,55	0,31	72,33	120,33
SMO	0,36	0,12	30,14	77,79	0,36	0,12	30,08	77,66
K-EYK	0,08	0,02	5,72	17,58	0,41	0,19	44,18	89,06
K-YILDIZ	0,11	0,02	6,02	24,58	0,46	0,22	51,11	99,72

4.2 Mikrodalga Verilerinden Sulu Çözeltilerdeki Tehlikeli Sıvı Konsantrasyonu Belirleme

Tehlikeli sıvı konsantrasyonu belirlemede su ile tamamen karışabilen Etanol, Metanol,1-Propanol ve isopropanol tercih edilmiştir. Sulu çözeltilerdeki alkol konsantrasyonu hacimce %10-100 arasında değişmektedir. Ayrıca veri setine etanol konsantrasyonuna sahip kolonya, kırmızı şarap, Votka, Viski ve Beyaz şarap ta eklenmiştir. Toplamda 45 adet sıvı kullanılmıştır. Bu sıvılardaki alkol konsantrasyonu bulmada 7 farklı algoritma kullanılmış ve algoritmaların performansları performans ölçütleri kullanılarak karşılaştırılmıştır.

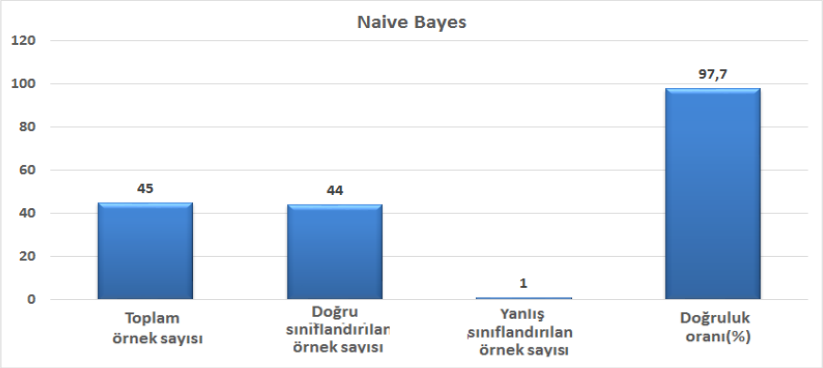
4.2.1 Tehlikeli Sıvı Konsantrasyonu Belirlemede Algoritmaların Performansının Değerlendirilmesi

Algoritmaların çözeltilerdeki tehlikeli sıvı konsantrasyonu bulma performanslarını karşılaştırmada performans ölçütü olarak doğru ve yanlış tahmin edilen sıvı sayısı, doğruluk değeri ve hata değerleri kullanılmıştır. Naive Bayes, DDA, KDA, DVM, SMO, K-EYK ve K-Yıldız algoritması olmak üzere 7 farklı algoritma kullanılarak sıvı tanıma yapılmış ve her algoritmanın doğru ve yanlış tahmin ettiği sıvı sayısı ile

doğruluk değeri grafikler halinde şekillerde gösterilmiştir. Grafik sonuçları karşılaştırılarak performans değerlendirmesi yapılmıştır.

4.2.1.1 Naive Bayes Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti

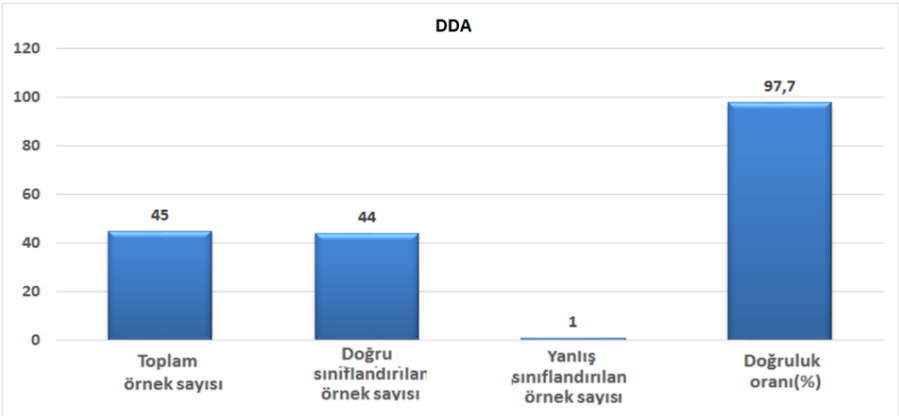
Bu algoritma kullanılan 45 adet sıvı içerisinden sadece 1 tane sıvının konsantrasyonunu yanlış tahmin etmiş ve %97,7 doğruluk oranına ulaşmıştır. Algoritmanın tahmin ettiği sıvı sayıları ve doğruluk oranını gösteren grafik Şekil 4.15'de verilmiştir.



Şekil 4.15. Naive Bayes ile tehlikeli sıvı konsantrasyonu bulma.

4.2.1.2 DDA Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti

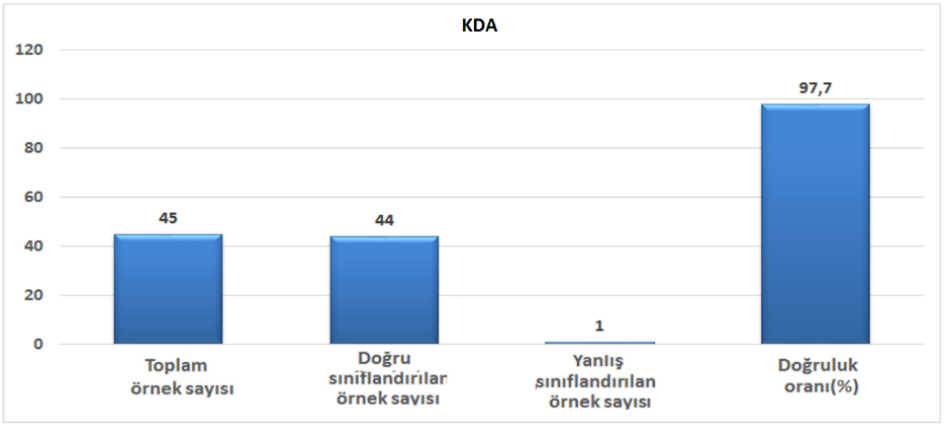
DDA algoritması da kullanılan 45 adet sıvı içerisinden sadece 1 tane sıvının konsantrasyonunu yanlış tahmin etmiş ve %97,7 doğruluk oranına ulaşmıştır. Algoritmanın tahmin ettiği sıvı sayıları ve doğruluk oranını gösteren grafik Şekil 4.16'da verilmiştir.



Şekil 4.16. DDA ile tehlikeli sıvı konsantrasyonu bulma.

4.2.1.3 KDA Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti

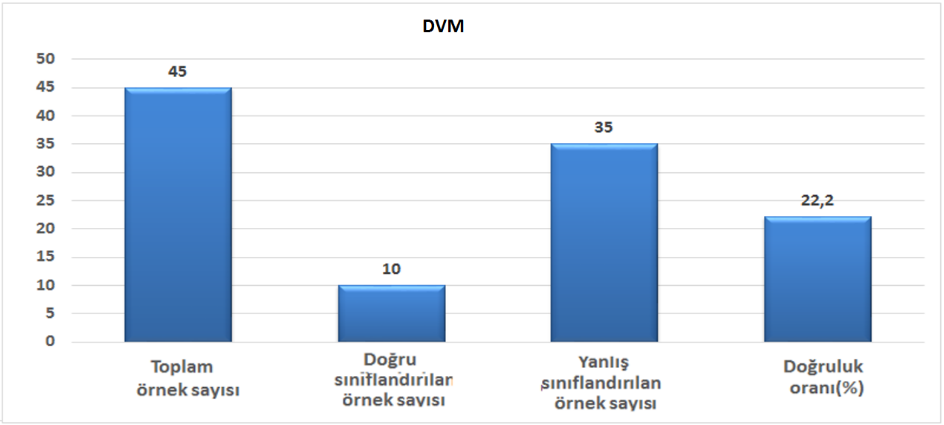
KDA algoritması da başarılı sonuç veren bir algoritma olmuştur. Sulu çözeltilerdeki tehlikeli sıvı konsantrasyonu belirlemede 45 sıvıdan 44 tanesinin konsantrasyonunu doğru tahmin ederek %97,7 doğruluk oranına ulaşmıştır. Algoritmanın tahmin ettiği sıvı sayıları ve doğruluk oranını gösteren grafik Şekil 4.17'de verilmiştir.



Şekil 4.17. KDA ile tehlikeli sıvı konsantrasyonu bulma.

4.2.1.4 DVM Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti

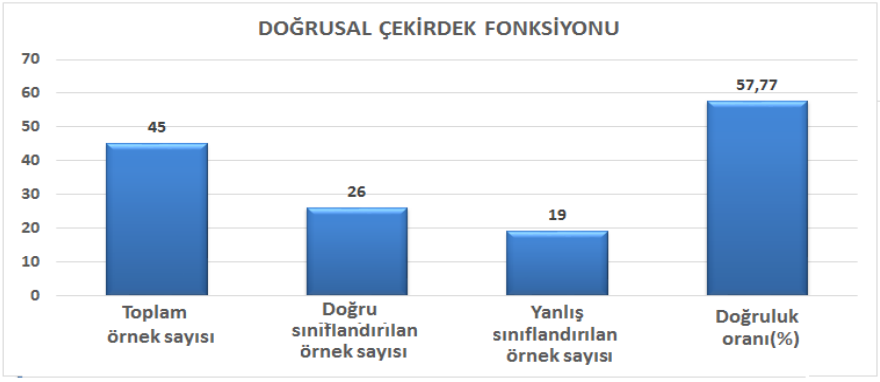
DVM algoritması diğer algoritmalara göre daha kötü bir performans göstermiştir. 45 sıvıdan sadece 10 tanesini doğru tahmin etmiştir. Algoritmanın yanlış tahmin ettiği sıvı sayısı ise doğru tahmin ettiği sıvı sayısından fazladır. Algoritmanın tahmin ettiği sıvı sayıları ve doğruluk oranını gösteren grafik Şekil 4.18' de verilmiştir.



Şekil 4.18. DVM ile tehlikeli sıvı konsantrasyonu bulma.

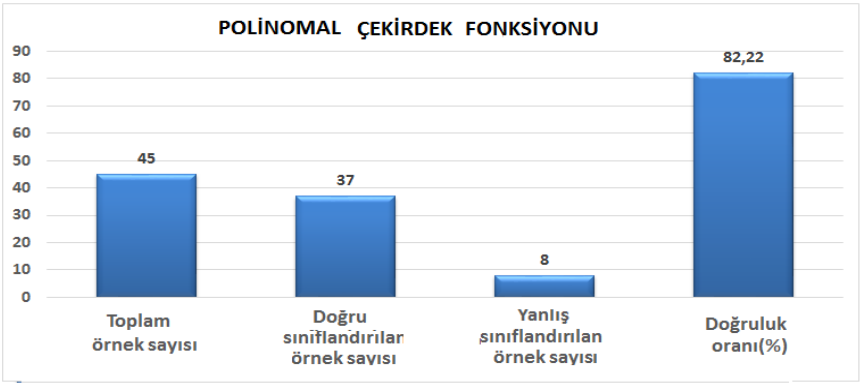
4.2.1.4.1 Tehlikeli Sıvı Konsantrasyonu Bulmada DVM Farklı Çekirdek Fonksiyon Kullanımı

Yapılan performans değerlendirmesinde en kötü performansa sahip olan en düşük doğruluk değeri veren DVM algoritmasının doğruluk değerinin arttırılabilmesine yönelik araştırmalar yapılmıştır. Bu kapsamda algoritmanın performansını çekirdek fonksiyon seçiminin etkileyip etkilemediği araştırılmıştır. Bunun için Doğrusal, Polinomal, Gauss Radyal Temel ve Sigmoid Çekirdek fonksiyonu olmak üzere 4 farklı çekirdek fonksiyonu kullanılarak sıvı tanıma gerçekleştirilmiştir. Sıvı tanıma sonucunda elde edilen doğru yanlış tahmin edilen sıvı sayısı doğruluk değerini veren grafikler Doğrusal çekirdek fonksiyon için Şekil 4.19'da, Polinomal fonksiyon için Şekil 4.20'de, Gauss radyal temel Şekil 4.21'de, Sigmoid fonksiyonu için Şekil 4.22'de gösterilmiştir.



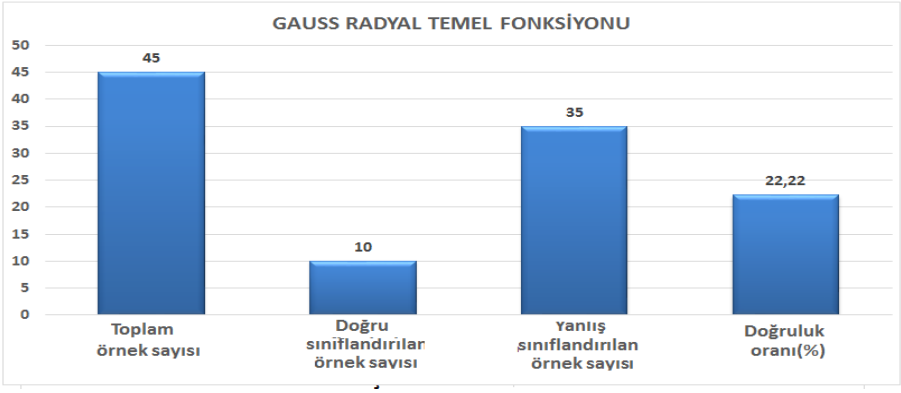
Şekil 4.19. Doğrusal çekirdek fonksiyonu performans ölçütleri.

Doğrusal çekirdek fonksiyonu kullanıldığında algoritma 45 adet sıvıdan 26 tane çözeltinin alkol konsantrasyonunu tahmin edilmiş ve %57,7 lik bir doğruluk oranı elde edilmiştir.



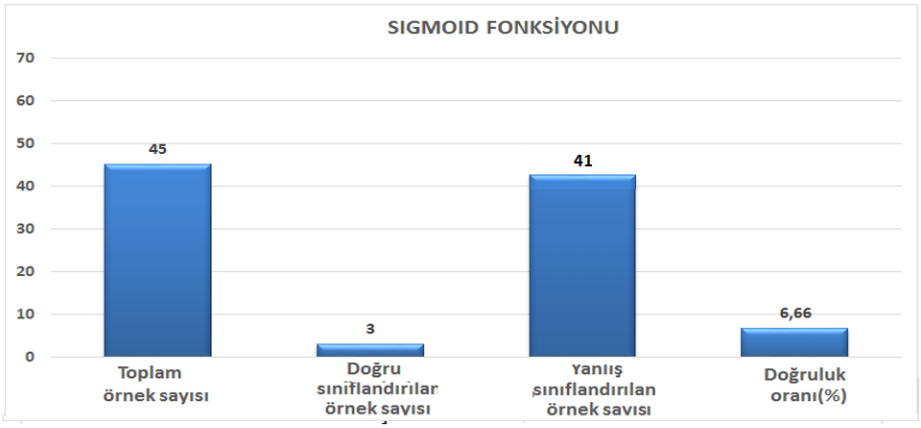
Şekil 4.20. Polinomal çekirdek fonksiyonu performans ölçütleri.

Çekirdek fonksiyonun Polinomal fonksiyon seçilmesi durumunda ise doğruluk oranı %84' e yükselmiş ve doğru tahmin edilen sıvı sayısı 37 olmuştur.



Şekil 4.21. Radyal Temel çekirdek fonksiyonu performans ölçütleri.

Radyal Temel fonksiyonunda ise doğu tahmin edilen sıvı sayısı 10 ve doğruluk oranı %22,2 'e düşmüştür.



Şekil 4.22. Sigmoid çekirdek fonksiyonu performans ölçütleri.

Algoritma en düşük doğruluk oranı olan %6,6 değerine Sigmoid fonksiyonunun kullanımı ile ulaşmıştır. Sadece 3 tane sıvının doğru tahmin edilmiştir. Farklı çekirdek fonksiyonu kullanılarak yapılan alkol konsantrasyonu bulma işleminde doğru ve yanlış tahmin edilen sıvılar Doğrusal fonksiyon kullanıldığında Çizelge 4.21'de Polinomal fonksiyon kullanıldığında Çizelge 4.22'de Gauss Radyal Temel fonksiyon kullanıldığında Çizelge 4.23'de ve Sigmoid Çekirdek fonksiyon kullanıldığında Çizelge 4.24'de verilmiştir.

Çizelge 4.22. Liner çekirdek DVM uygulaması ile tehlikeli sıvı konsantrasyonu doğru ve yanlış tahmin edilen sıvılar.

Alkol Türü	**Gerçek (%)**	**Tahmin edilen (%)**	**Doğru/yanlış**
Kırmızı şarap	12% Etanol	10% Etanol	Doğru
Votka	40% Etanol	40% Etanol	Doğru
Viski	40% Etanol	40% Etanol	Doğru
Beyaz şarap	12% Etanol	10% Etanol	Doğru
Kolonya	%80 Etanol	%80 Etanol	Doğru
Etanol	%10 Etanol	%10 Etanol	Doğru
	%20 Etanol	%40 Etanol	Yanlış
	%30 Etanol	%40 Etanol	Yanlış
	%40 Etanol	%40 Etanol	Doğru
	%50 Etanol	%50 Etanol	Doğru
	%60 Etanol	%60 Etanol	Doğru
	%70 Etanol	%70 Etanol	Doğru
	%80 Etanol	%80 Etanol	Doğru
	%90 Etanol	%80 Etanol	Yanlış
	%100 Etanol	%100 Etanol	Doğru
Metanol	%10 Metanol	%10Etanol	Yanlış
	%20 Metanol	%10Etanol	Yanlış
	%30 Metanol	%10Etanol	Yanlış
	%40 Metanol	%40 Etanol	Yanlış
	%50 Metanol	%40 Etanol	Yanlış
	%60 Metanol	%40 Etanol	Yanlış
	%70 Metanol	%40 Etanol	Yanlış
	%80 Metanol	%40 Etanol	Yanlış
	%90 Metanol	%90 Metanol	Doğru
	%100 Etanol	%40 İsopropanol	Yanlış
1-propanol	%10 1-propanol	%10 Etanol	Yanlış
	%20 1-propanol	%40 Etanol	Yanlış
	%30 1-propanol	%30 1-propanol	Doğru
	%40 1-propanol	%40 1-propanol	Doğru
	%50 1-propanol	%50 1-propanol	Doğru
	%60 1-propanol	%80 Etanol	Yanlış
	%70 1-propanol	%80 Etanol	Yanlış
	%80 1-propanol	%80 1-propanol	Doğru
	%90 1-propanol	%90 1-propanol	Doğru
	%100 1-propanol	%100 1-propanol	Doğru
İsopropanol	%10 İsopropanol	%10Etanol	Yanlış
	%20 İsopropanol	%40 Etanol	Yanlış
	%30 İsopropanol	%30 İsopropanol	Doğru
	%40 İsopropanol	%40 İsopropanol	Doğru
	%50 İsopropanol	%50 İsopropanol	Doğru
	%60 İsopropanol	%80 Etanol	Yanlış
	%70 İsopropanol	%70 İsopropanol	Doğru
	%80 İsopropanol	%80 İsopropanol	Doğru
	%90 İsopropanol	%90 İsopropanol	Doğru
	%100 İsopropanol	%100 İsopropanol	Doğru

Çizelge 4.23. Polinomal çekirdek DVM uygulaması ile tehlikeli sıvı konsantrasyonu doğru ve yanlış tahmin edilen sıvılar.

Alkol Türü	**Gerçek (%)**	**Tahmin edilen (%)**	**Doğru/yanlış**
Kırmızı şarap	12% Etanol	%10 Etanol	Doğru
Votka	40% Etanol	40% Etanol	Doğru
Viski	40% Etanol	40% Etanol	Doğru
Beyaz şarap	12% Etanol	%10 Etanol	Doğru
Kolonya	%80 Etanol	%80 Etanol	Doğru
Etanol	%10 Etanol	%10 Etanol	Doğru
	%20 Etanol	%20 Etanol	Doğru
	%30 Etanol	%40 Etanol	Yanlış
	%40 Etanol	%40 Etanol	Doğru
	%50 Etanol	%50 Etanol	Doğru
	%60 Etanol	%60 Etanol	Doğru
	%70 Etanol	%70 Etanol	Doğru
	%80 Etanol	%80 Etanol	Doğru
	%90 Etanol	%90 Etanol	Doğru
	%100 Etanol	%100 Etanol	Doğru
Metanol	%10 Metanol	%10 Etanol	Yanlış
	%20 Metanol	%10 Etanol	Yanlış
	%30 Metanol	%30 Metanol	Doğru
	%40 Metanol	%40 Metanol	Doğru
	%50 Metanol	%40 Etanol	Yanlış
	%60 Metanol	%40 Etanol	Yanlış
	%70 Metanol	%40 Metanol	Yanlış
	%80 Metanol	%80 Metanol	Doğru
	%90 Metanol	%90 Metanol	Doğru
	%100 Etanol	%40 İsopropanol	Yanlış
1-propanol	%10 1-propanol	%10 1-propanol	Doğru
	%20 1-propanol	%40 Etanol	Yanlış
	%30 1-propanol	%30 1-propanol	Doğru
	%40 1-propanol	%40 1-propanol	Doğru
	%50 1-propanol	%50 1-propanol	Doğru
	%60 1-propanol	%60 1-propanol	Doğru
	%70 1-propanol	%70 1-propanol	Doğru
	%80 1-propanol	%80 1-propanol	Doğru
	%90 1-propanol	%90 1-propanol	Doğru
	%100 1-propanol	%100 1-propanol	Doğru
İsopropanol	%10 İsopropanol	%10 İsopropanol	Doğru
	%20 İsopropanol	%20 İsopropanol	Doğru
	%30 İsopropanol	%30 İsopropanol	Doğru
	%40 İsopropanol	%40 İsopropanol	Doğru
	%50 İsopropanol	%50 İsopropanol	Doğru
	%60 İsopropanol	%60 İsopropanol	Doğru
	%70 İsopropanol	%70 İsopropanol	Doğru
	%80 İsopropanol	%80 İsopropanol	Doğru
	%90 İsopropanol	%90 İsopropanol	Doğru
	%100 İsopropanol	%100 İsopropanol	Doğru

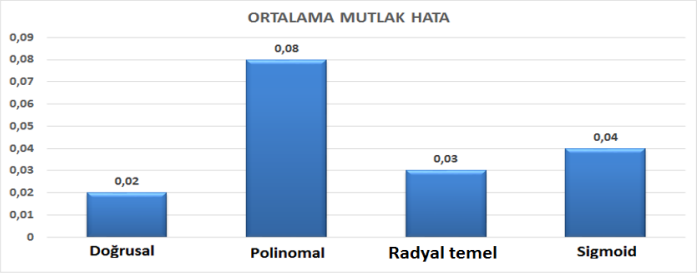
Çizelge 4.24. Radyal temel çekirdek fonksiyonu DVM uygulaması ile tehlikeli sıvı konsantrasyonu doğru ve yanlış tahmin edilen sıvılar.

Alkol Türü	**Gerçek (%)**	**Tahmin edilen (%)**	**Doğru/yanlış**
Kırmızı şarap	12% Etanol	%10 Etanol	Doğru
Votka	40% Etanol	40% Etanol	Doğru
Viski	40% Etanol	40% Etanol	Doğru
Beyaz şarap	12% Etanol	%10 Etanol	Doğru
Kolonya	%80 Etanol	%80 Etanol	Doğru
Etanol	%10 Etanol	%10 Etanol	Doğru
	%20 Etanol	%10 Etanol	Yanlış
	%30 Etanol	40% Etanol	Yanlış
	%40 Etanol	40% Etanol	Doğru
	%50 Etanol	40% Etanol	Yanlış
	%60 Etanol	40% Etanol	Yanlış
	%70 Etanol	40% Etanol	Yanlış
	%80 Etanol	%80 Etanol	Doğru
	%90 Etanol	%80 Etanol	Yanlış
	%100 Etanol	%80 Etanol	Yanlış
Metanol	%10 Metanol	%10 Etanol	Yanlış
	%20 Metanol	%10 Etanol	Yanlış
	%30 Metanol	%10 Etanol	Yanlış
	%40 Metanol	40% Etanol	Yanlış
	%50 Metanol	40% Etanol	Yanlış
	%60 Metanol	40% Etanol	Yanlış
	%70 Metanol	40% Etanol	Yanlış
	%80 Metanol	40% Etanol	Yanlış
	%90 Metanol	40% Etanol	Yanlış
	%100 Etanol	40% Etanol	Yanlış
1-propanol	%10 1-propanol	%10 Etanol	Yanlış
	%20 1-propanol	40% Etanol	Yanlış
	%30 1-propanol	40% Etanol	Yanlış
	%40 1-propanol	40% Etanol	Yanlış
	%50 1-propanol	40% Etanol	Yanlış
	%60 1-propanol	%80 Etanol	Yanlış
	%70 1-propanol	%80 Etanol	Yanlış
	%80 1-propanol	%80 Etanol	Yanlış
	%90 1-propanol	%80 Etanol	Yanlış
	%100 1-propanol	%100 1-propanol	Doğru
İsopropanol	%10 İsopropanol	%10 Etanol	Yanlış
	%20 İsopropanol	40% Etanol	Yanlış
	%30 İsopropanol	%30 İsopropanol	Doğru
	%40 İsopropanol	40% Etanol	Yanlış
	%50 İsopropanol	40% Etanol	Yanlış
	%60 İsopropanol	40% Etanol	Yanlış
	%70 İsopropanol	%80 Etanol	Yanlış
	%80 İsopropanol	%80 Etanol	Yanlış
	%90 İsopropanol	%80 Etanol	Yanlış
	%100 İsopropanol	%80 Etanol	Yanlış

Çizelge 4.25. Sigmoid çekirdek DVM uygulaması ile tehlikeli sıvı konsantrasyonu doğru ve yanlış tahmin edilen sıvılar.

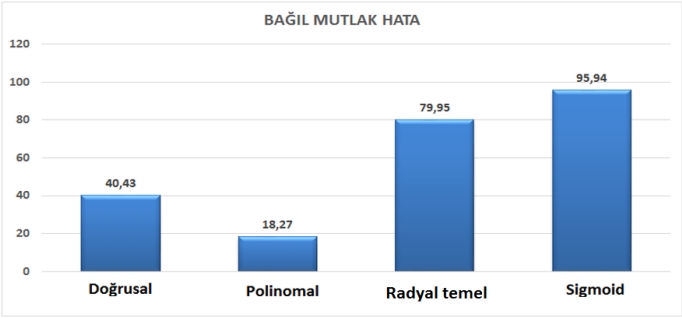
Alkol Türü	Gerçek (%)	Tahmin edilen (%)	Doğru/yanlış
Kırmızı şarap	12% Etanol	%40 Etanol	Yanlış
Votka	40% Etanol	%40 Etanol	Doğru
Viski	40% Etanol	%40 Etanol	Doğru
Beyaz şarap	12% Etanol	%40 Etanol	Yanlış
Kolonya	%80 Etanol	%40 Etanol	Yanlış
Etanol	%10 Etanol	%40 Etanol	Yanlış
	%20 Etanol	%40 Etanol	Yanlış
	%30 Etanol	%40 Etanol	Yanlış
	%40 Etanol	%40 Etanol	Doğru
	%50 Etanol	%40 Etanol	Yanlış
	%60 Etanol	%40 Etanol	Yanlış
	%70 Etanol	%40 Etanol	Yanlış
	%80 Etanol	%40 Etanol	Yanlış
	%90 Etanol	%40 Etanol	Yanlış
	%100 Etanol	%40 Etanol	Yanlış
Metanol	%10 Metanol	%40 Etanol	Yanlış
	%20 Metanol	%40 Etanol	Yanlış
	%30 Metanol	%40 Etanol	Yanlış
	%40 Metanol	%40 Etanol	Yanlış
	%50 Metanol	%40 Etanol	Yanlış
	%60 Metanol	%40 Etanol	Yanlış
	%70 Metanol	%40 Etanol	Yanlış
	%80 Metanol	%40 Etanol	Yanlış
	%90 Metanol	%40 Etanol	Yanlış
	%100 Etanol	%40 Etanol	Yanlış
1-propanol	%10 1-propanol	%40 Etanol	Yanlış
	%20 1-propanol	%40 Etanol	Yanlış
	%30 1-propanol	%40 Etanol	Yanlış
	%40 1-propanol	%40 Etanol	Yanlış
	%50 1-propanol	%40 Etanol	Yanlış
	%60 1-propanol	%40 Etanol	Yanlış
	%70 1-propanol	%40 Etanol	Yanlış
	%80 1-propanol	%40 Etanol	Yanlış
	%90 1-propanol	%40 Etanol	Yanlış
	%100 1-propanol	%40 Etanol	Yanlış
İsopropanol	%10 İsopropanol	%40 Etanol	Yanlış
	%20 İsopropanol	%40 Etanol	Yanlış
	%30 İsopropanol	%40 Etanol	Yanlış
	%40 İsopropanol	%40 Etanol	Yanlış
	%50 İsopropanol	%40 Etanol	Yanlış
	%60 İsopropanol	%40 Etanol	Yanlış
	%70 İsopropanol	%40 Etanol	Yanlış
	%80 İsopropanol	%40 Etanol	Yanlış
	%90 İsopropanol	%40 Etanol	Yanlış
	%100 İsopropanol	%40 Etanol	Yanlış

Farklı çekirdek fonksiyonu kullanmanın hata değerlerine olan etkisini incelemek için yapılan sınıflandırmalardan elde edilen ortalama mutlak hata değerleri Şekil 4.23'te, bağıl mutlak hata değerleri Şekil 4.24'te, kök ortalama kare hata değerleri Şekil 4.25'te, kök bağıl kare hata değerleri Şekil 4.26'da verilmiştir.



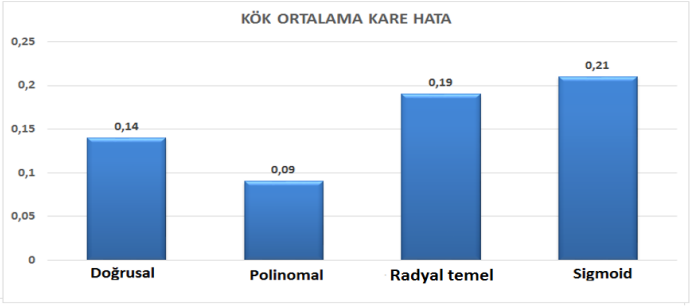
Şekil 4.23. Farklı çekirdek fonksiyonlarının ortalama mutlak hatası.

Şekil 4.23 incelendiğinde en yüksek hata değerinin Polinomal fonksiyon kullanıldığında, en düşük hata değerinin ise Doğrusal fonksiyon kullanımında elde edildiği görülmektedir.



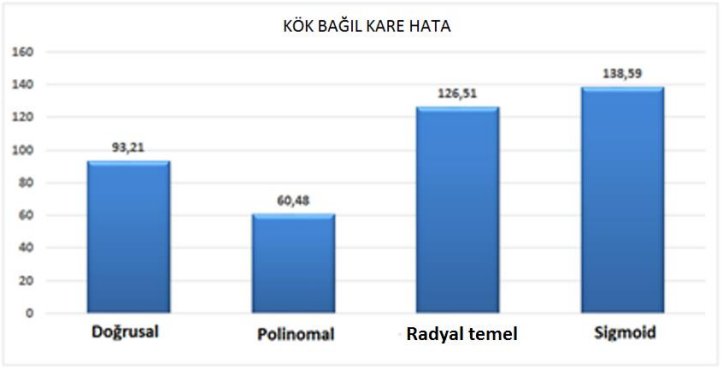
Şekil 4.24. Farklı çekirdek fonksiyonlarının bağıl mutlak hatası.

Bağıl mutlak hata değeri ise %95,4 ile Sigmoid en yüksek değeri vermiştir. En düşük hata değeri de Polinomal fonksiyon kullanımında elde edilmiştir.



Şekil 4.25. Farklı çekirdek fonksiyonlarının kök ortalama kare hatası.

Kök ortalama kare hatasında Radyal temel ve Sigmoid fonksiyonları birbirlerine yaklaşık değerler vermişlerdir. En düşük hata değeri Polinomal fonksiyon kullanımında elde edilmiştir.

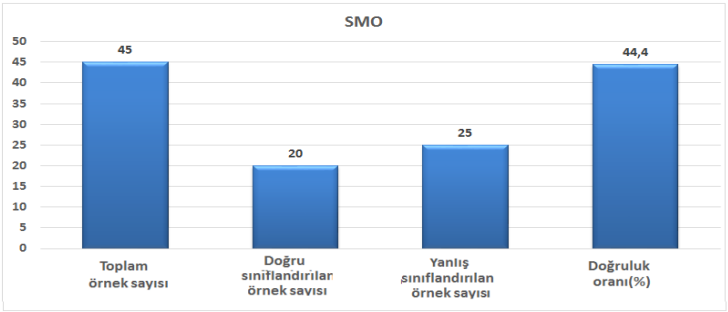


Şekil 4.26.Farklı çekirdek fonksiyonlarının kök bağıl kare hatası.

En düşük kök ortalama kare hatası hesabı polinomal fonksiyon kullanımı ile elde edilmiştir.

4.2.1.5 SMO Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti

SMO algoritması DVM algoritmasına göre daha iyi bir performans göstermiştir. 45 sıvıdan sadece 20 tanesini doğru tahmin etmiştir. Algoritmanın yanlış tahmin ettiği sıvı sayısı ise 25'tir. Algoritmanın tahmin ettiği sıvı sayıları ve doğruluk oranını gösteren grafik Şekil 4.27'de verilmiştir.



Şekil 4.27. SMO ile tehlikeli sıvı konsantrasyonu bulma.

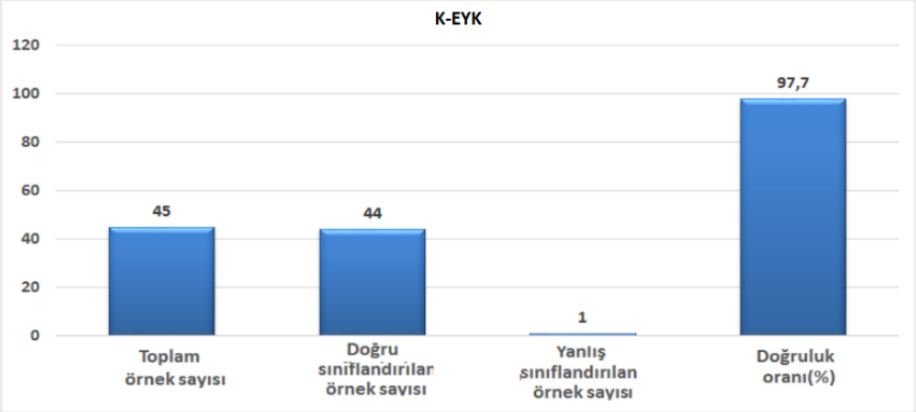
SMO algoritması ile alkol konsantrasyonu doğru ve yanlış tahmin edilen sıvılar Çizelge 4.25'te verilmiştir.

Çizelge 4.26. SMO ile alkol konsantrasyonu doğru ve yanlış tahmin edilen sıvılar.

Alkol Türü	**Gerçek (%)**	**Tahmin edilen (%)**	**Doğru/yanlış**
Kırmızı şarap	12% Etanol	10% Etanol	Doğru
Votka	40% Etanol	40% Etanol	Doğru
Viski	40% Etanol	40% Etanol	Doğru
Beyaz şarap	12% Etanol	10% Etanol	Doğru
Kolonya	%80 Etanol	%80 Etanol	Doğru
Etanol	%10 Etanol	%10 Etanol	Doğru
	%20 Etanol	%40 Etanol	Yanlış
	%30 Etanol	%40 Etanol	Yanlış
	%40 Etanol	%40 Etanol	Doğru
	%50 Etanol	%40 Etanol	Yanlış
	%60 Etanol	%60 Etanol	Doğru
	%70 Etanol	%80 Etanol	Yanlış
	%80 Etanol	%80 Etanol	Doğru
	%90 Etanol	%80 Etanol	Yanlış
	%100 Etanol	%100 Etanol	Doğru
Metanol	%10 Metanol	%10 Etanol	Yanlış
	%20 Metanol	%10 Etanol	Yanlış
	%30 Metanol	%10 Etanol	Yanlış
	%40 Metanol	%40 Etanol	Yanlış
	%50 Metanol	%40 Etanol	Yanlış
	%60 Metanol	%40 Etanol	Yanlış
	%70 Metanol	%40 Etanol	Yanlış
	%80 Metanol	%40 Etanol	Yanlış
	%90 Metanol	%90 Metanol	Doğru
	%100 Etanol	%100 Etanol	Doğru
1-propanol	%10 1-propanol	%10 Etanol	Yanlış
	%20 1-propanol	%40 Etanol	Yanlış
	%30 1-propanol	%30 1-propanol	Doğru
	%40 1-propanol	%40 1-propanol	Doğru
	%50 1-propanol	%80 Etanol	Yanlış
	%60 1-propanol	%80 Etanol	Yanlış
	%70 1-propanol	%80 Etanol	Yanlış
	%80 1-propanol	%80 1-propanol	Doğru
	%90 1-propanol	%90 1-propanol	Doğru
	%100 1-propanol	%100 1-propanol	Doğru
İsopropanol	%10 İsopropanol	%10 Etanol	Yanlış
	%20 İsopropanol	%40 Etanol	Yanlış
	%30 İsopropanol	%30 İsopropanol	Doğru
	%40 İsopropanol	%100 Metanol	Yanlış
	%50 İsopropanol	%80 Etanol	Yanlış
	%60 İsopropanol	%80 Etanol	Yanlış
	%70 İsopropanol	%80 Etanol	Yanlış
	%80 İsopropanol	%80 Etanol	Yanlış
	%90 İsopropanol	%90 İsopropanol	Doğru
	%100 İsopropanol	%100 İsopropanol	Doğru

4.2.1.6 K-EYK Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti

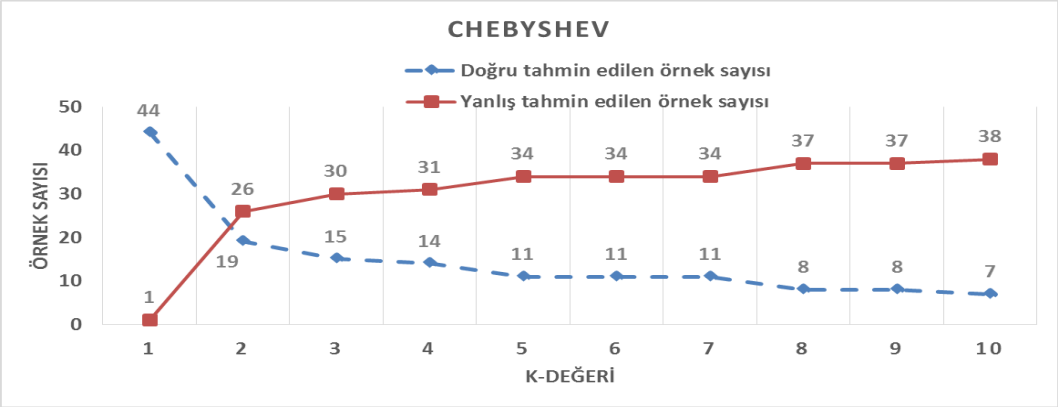
K-EYK algoritması da Naive bayes, KDA, DDA algoritmaları gibi yüksek doğruluk oranına sahiptir. Algoritmanın doğru ve yanlış tahmin ettiği sıvı sayısı ile doğruluk oranını gösteren grafik Şekil 4.28'de verilmiştir.



Şekil 4.28. K-EYK ile tehlikeli sıvı konsantrasyonu bulma.

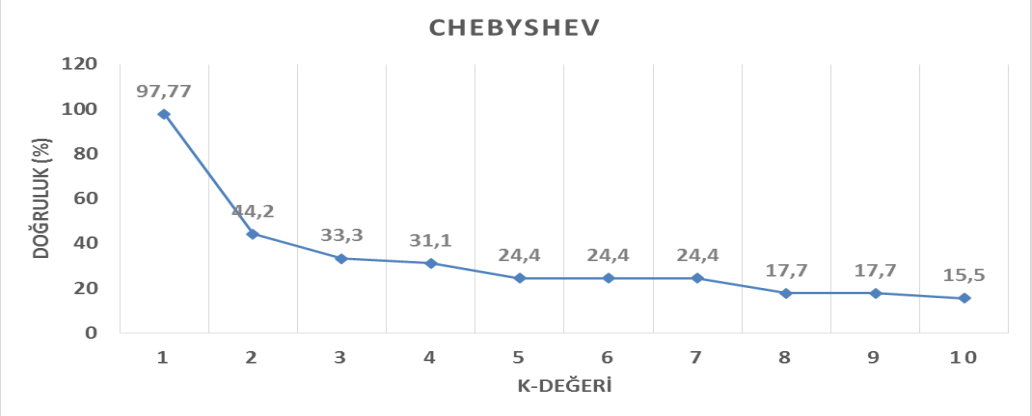
4.2.1.6.1 K-EYK Parametrelerinin Alkol Konsantrsasyonu Bulmaya Etkisi

Çözeltilerdeki tehlikeli sıvı konsantrasyonu bulmada iyi bir performans sağlayan algoritmalardan biri de K-EYK algoritmasıdır. Bu nedenle bu performansa etki eden algoritma parametreleri araştırılmıştır. K-EYK algoritması parametreleri olarak *k* değeri, farklı uzaklık ölçütleri ve ağırlıklandırma işlemi kullanılmıştır. Farklı uzaklık metrikleri ve farklı *k* değeri kullanılarak yapılan sıvı tanıma çalışmalarında algoritmanın performansını incelemek için doğru ve yanlış tahmin edilen sıvı sayısı ile algoritmanın doğruluk oranı kullanılmış ve sonuçlar grafikler halinde verilmiştir. İlk uzaklık ölçütü olarak Chebyshev uzaklığı kullanılmıştır. Bu uzaklık kullanılarak komşu sayısı 1 ile 10 arasında değiştirilerek sıvı tanıma yapılmıştır. Yapılan sıvı tanımada algoritmanın doğru ve yanlış tahmin ettiği sıvı sayısındaki değişim Şekil 4.29'da, doğruluk değerindeki değişim ise Şekil 4.30'da gösterilmiştir.



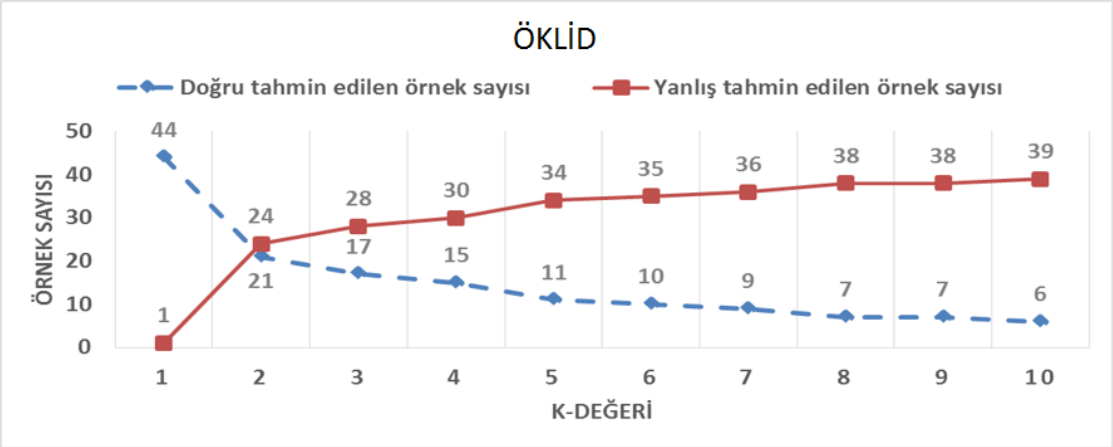
Şekil 4.29. Chebyshev uzaklığında doğru ve yanlış tahmin edilen sıvı sayısındaki değişim.

Grafikte, kesikli çizgiler doğru tahmin edilen sıvı sayısını düz çizgiler de yanlış tahmin edilen sıvı sayısını göstermektedir. Grafik incelendiğinde komşu sayısı 1 iken algoritmanın en yüksek doğru sayısı olan 44 değerine ulaştığı 45 sıvıdan sadece 1 tanesini yanlış tahmin ettiği görülmüştür. Doğru sayısı *k* değerinin artması ile azalırken yanlış sayısı *k* değerinin artmasıyla artmaktadır. Şekil 4.30'da verilen doğruluk değeri da *k* değerinin artmasıyla genel olarak azalmaktadır.

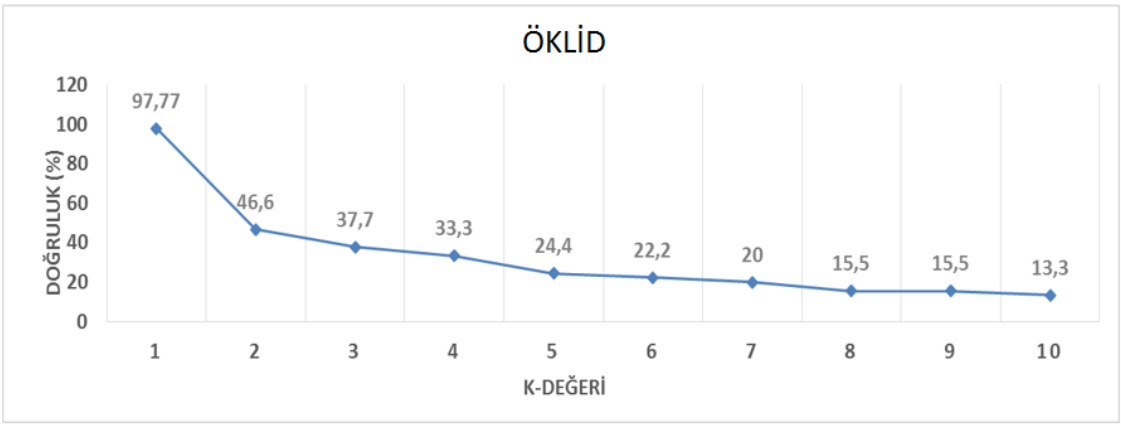


Şekil 4.30. Chebyshev uzaklığında doğruluk değerindeki değişim.

Aynı şekilde sıvı tanımada Öklid uzaklığı kullanılarak farklı *k* değeri için elde edilen doğru ve yanlış sıvı sayısı grafiği Şekil 4.31'de doğruluk oranı Şekil 4.32'de verilmiştir.

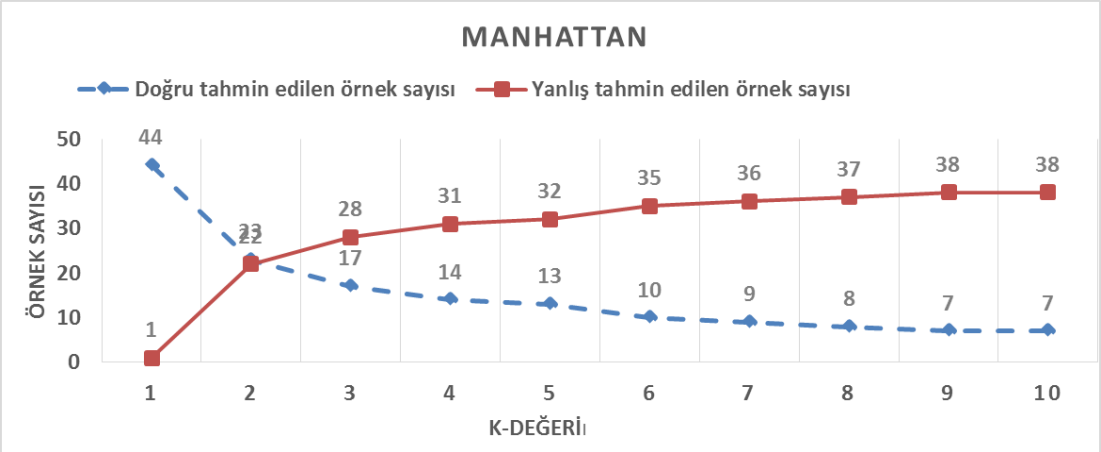


Şekil 4.31. Öklid uzaklığında doğru ve yanlış tahmin edilen sıvı sayısındaki değişim.

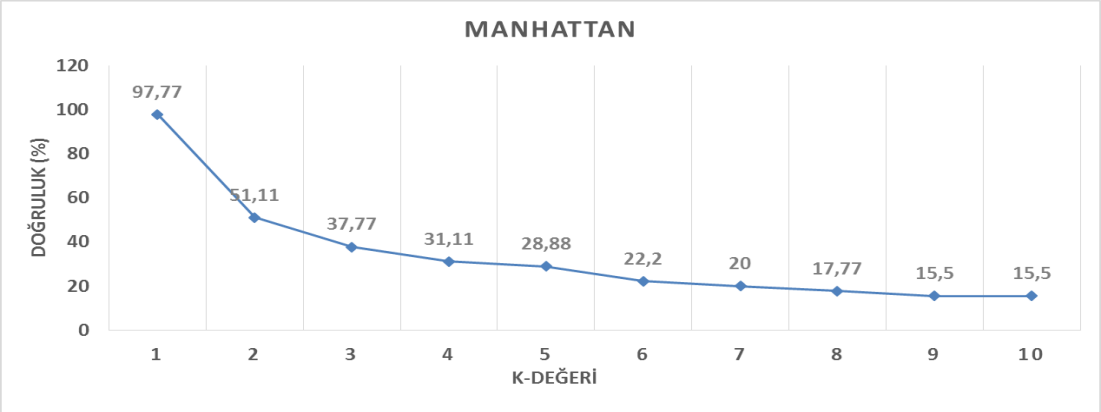


Şekil 4.32.Öklid uzaklığında doğruluk değerindeki değişim.

Öklid uzaklığı için de *k* değerinin artması doğru tahmin edilen sıvı sayısında azalışa yanlış tahmin edilen sıvı sayısında artışa neden olmuştur. Doğruluk oranı da doğru sayısında olduğu gibi *k* değerinin artması ile azalmıştır. Diğer uzaklık ölçütleri olan Manhattan ve Minkowski uzaklıkları için de *k* değeri değişiminin doğru ve yanlış sayılarına etkilerinin incelenmesi için yapılan sıvı tanıma sonuçları şekiller halinde gösterilmiştir. Doğru ve yanlış tahmin edilen sıvı sayısındaki değişim grafikleri Manhattan uzaklığı için Şekil 4.33'de Minkowski uzaklığı için Şekil 4.35'de verilmiştir. Doğruluk değerindeki değişim grafikleri ise yine sırasıyla Manhattan uzaklığı için Şekil 4.34' ve Minkowski uzaklığı için Şekil 4.36' da gösterilmiştir.

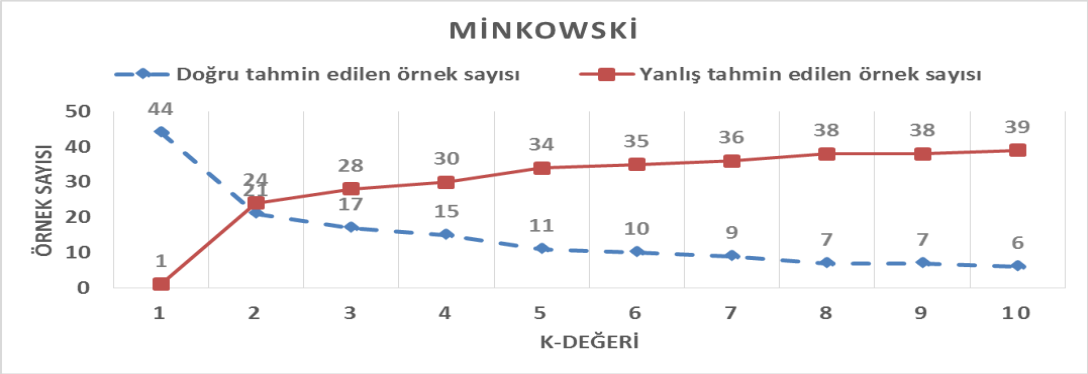


Şekil 4.33.Manhattan uzaklığında doğru ve yanlış tahmin edilen sıvı sayısındaki değişim.

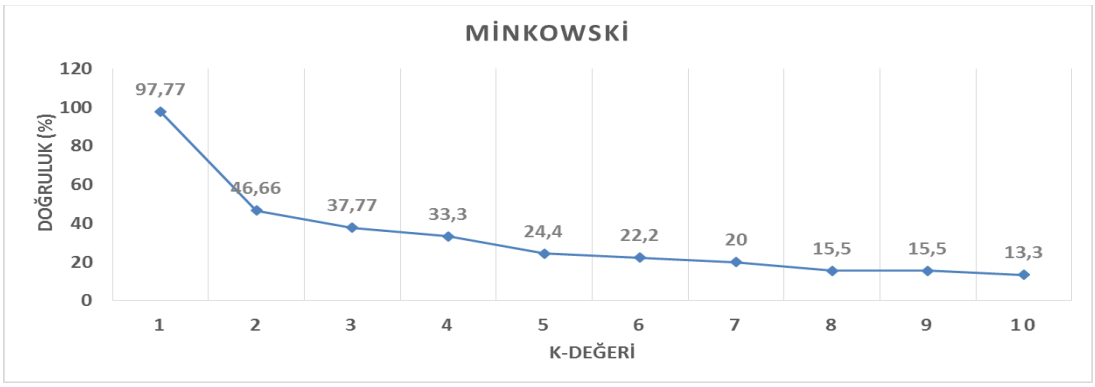


Şekil 4.34. Manhattan uzaklığında doğruluk değerindeki değişim.

Bu grafiklerde diğer uzaklık ölçütlerinde olduğu gibi bu uzaklık ölçütünün kullanılmasında da *k* değerinin artması doğru tahmin edilen sıvı sayısında ve doğruluk değerinde azalışın olduğunu, yanlış tahmin edilen sıvı sayısında artış olduğunu göstermektedir.

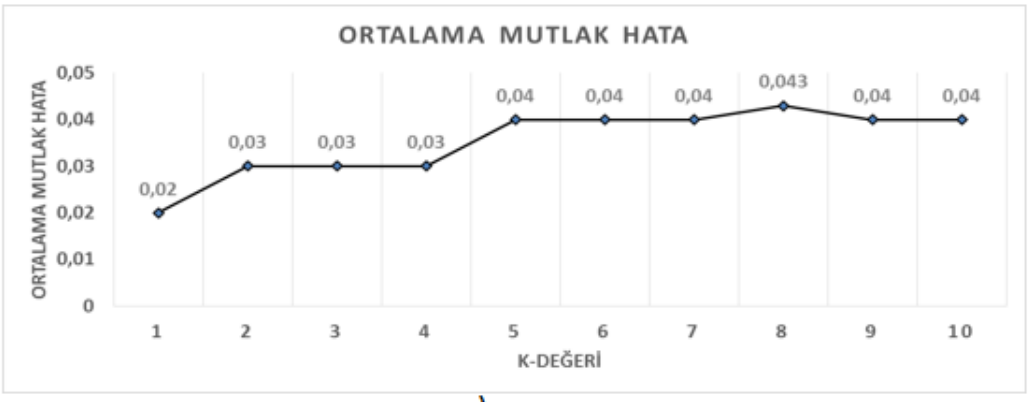


Şekil 4.35. Minkowski uzaklığında doğru ve yanlış tahmin edilen sıvı sayısındaki değişim.

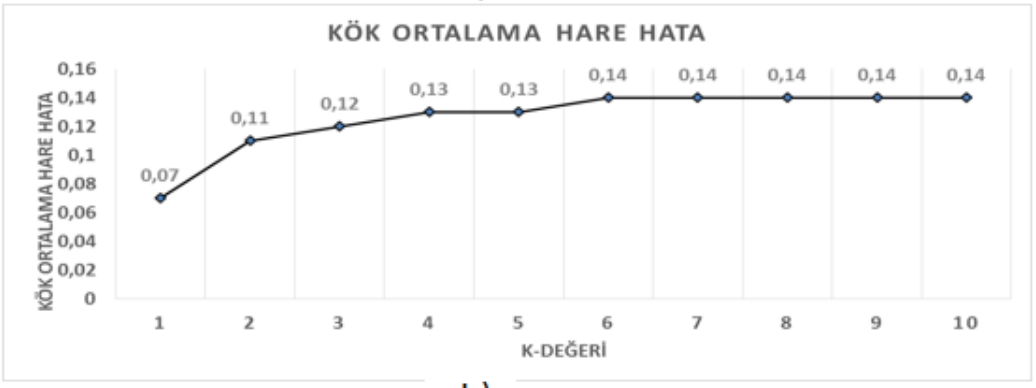


Şekil 4.36. Minkowski uzaklığında doğruluk değerindeki değişim.

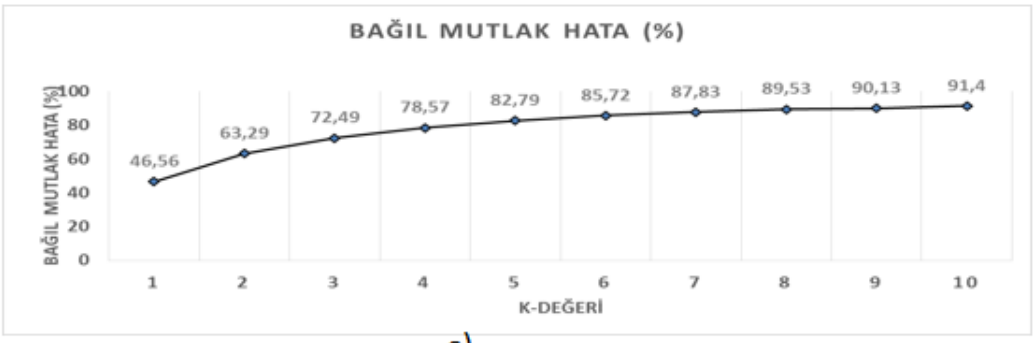
Görüldüğü üzere bütün uzaklık ölçütlerinin kullanılmasında *k* değerinin artması algoritmanın performansında bir düşüşe neden olmuştur. Uzaklık metrikleri ve *k* değeri değiştirilerek algoritma ortalama hata, kök ortalama kare hata, bağıl mutlak hata kök bağıl hata değerini değişimi incelenmiştir. Bütün uzaklık metriklerine ait hata değerlerinde değişim *k* değerinin 5 ten küçük seçilmesinde gözlenmiştir. *K* değerinin 5 ve 5 'ten büyük bir değer alması durumunda hata değerinde çok fazla bir değişim olmamaktadır. En düşük hata değeri tüm uzaklık metrikleri ve hata ölçütlerinde *k* değerinin 1 seçilmesi ile elde edilmiştir. Bu değer *k* değerinin artması ile artmaktadır. K-EYK algoritmasının *k* değerinin değişimi ile hata metriklerinin nasıl değiştiği incelenmiş ve her uzaklığa ait hata grafikleri sunulmuştur. Chebyshev uzaklığına ait grafik Şekil 4.37'de, Öklid uzaklığına ait grafik Şekil 4.38'de, Manhattan uzaklığına ait grafik Şekil 4.39'da, Minkowski uzaklığına ait grafik Şekil 4.40'ta görülmektedir.



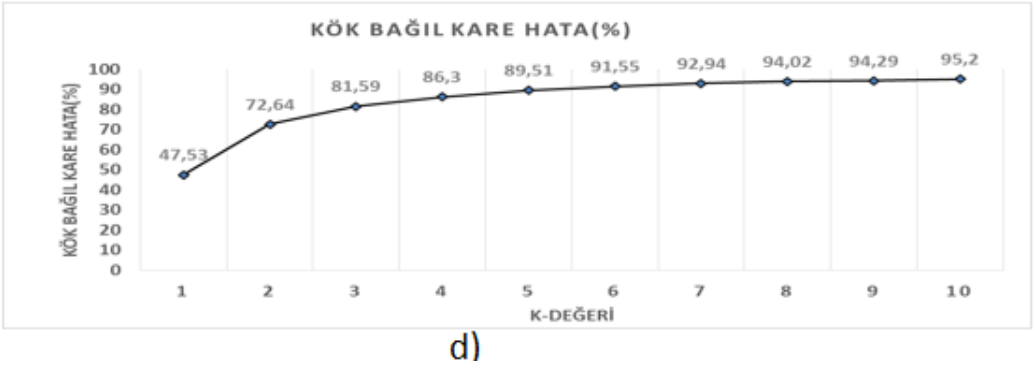
a)



b)

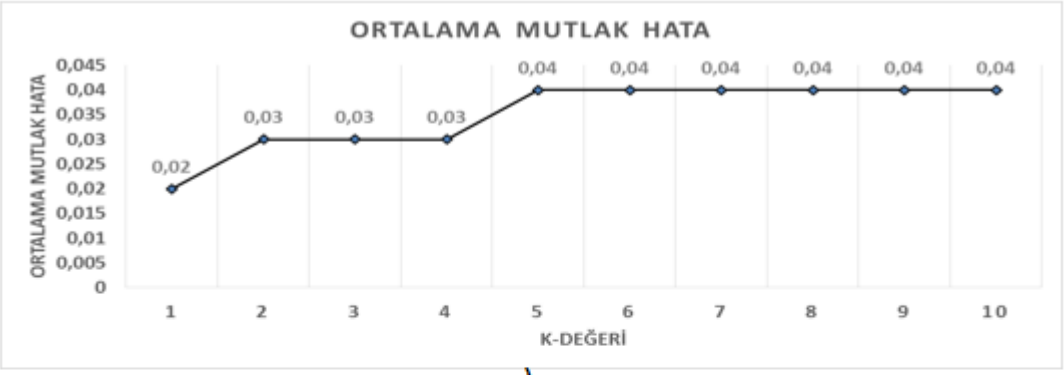


c)

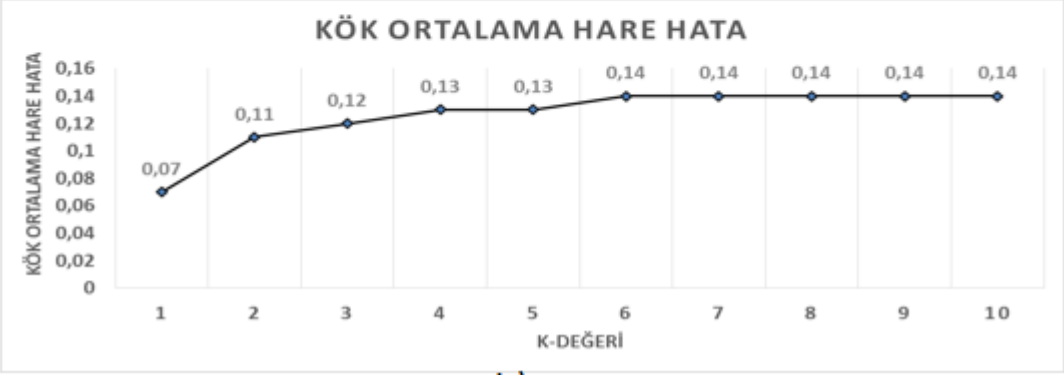


d)

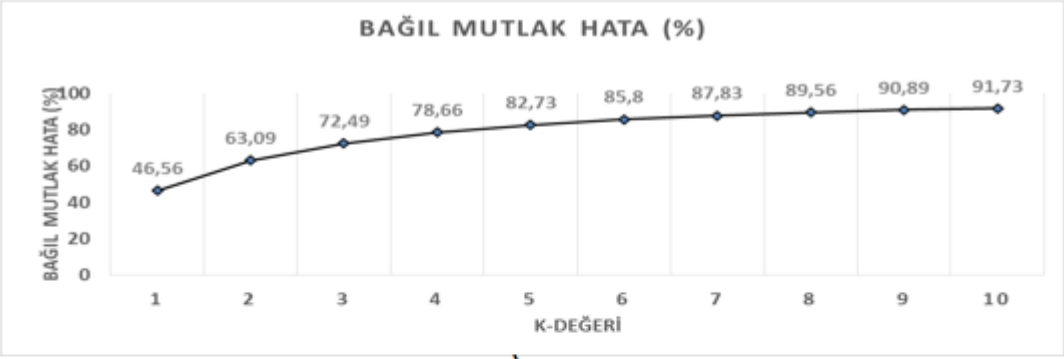
Şekil 4.37. Chebyshev uzaklığına ait hata değerleri a) Ortalama mutlak hata b) Kök ortalama kare hata c) Bağıl mutlak hata d) Kök bağıl kare hata.



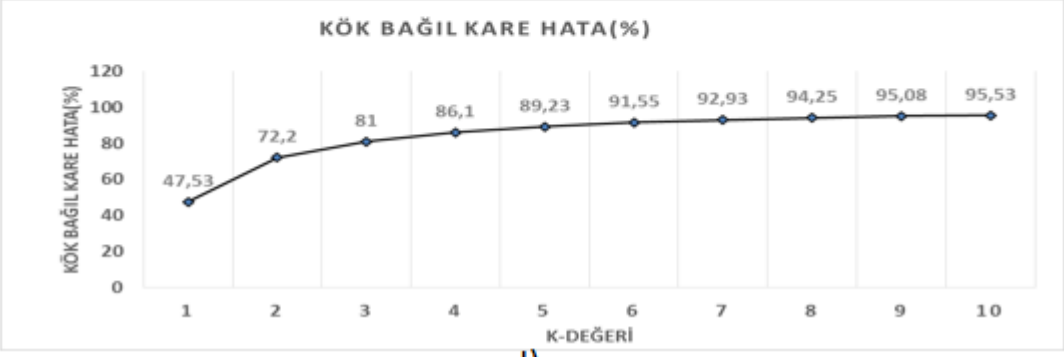
a)



b)

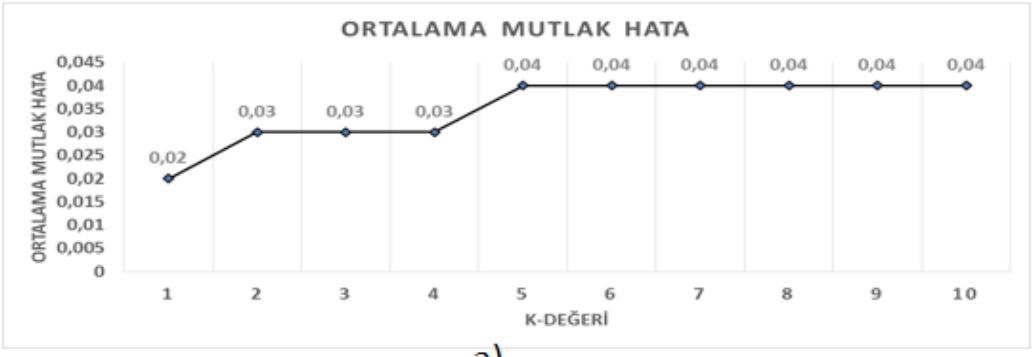


c)

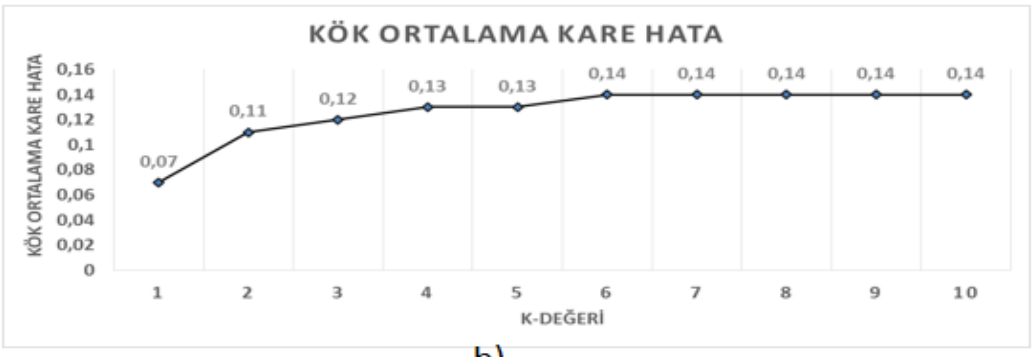


d)

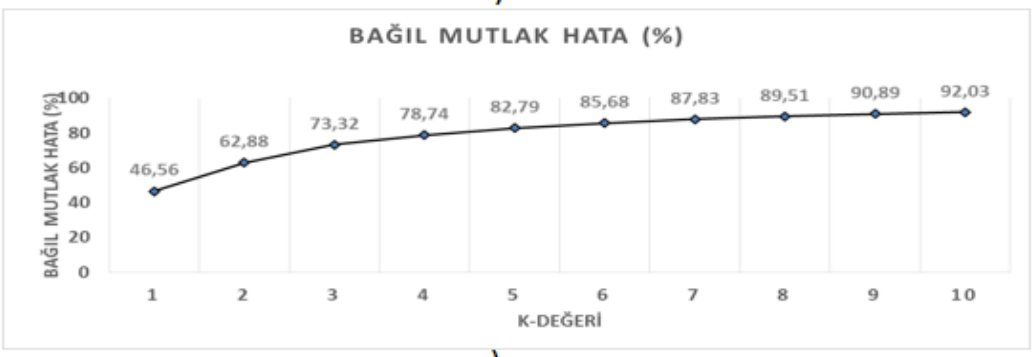
Şekil 4.38. Öklid uzaklığına ait hata değerleri a)Ortalama mutlak hata b)Kök ortalama kare hata c)Bağıl mutlak hata d)Kök bağıl kare hata.



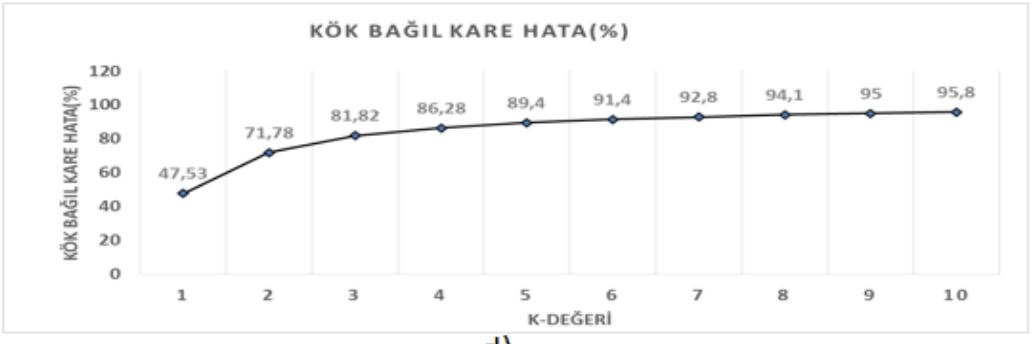
a)



b)

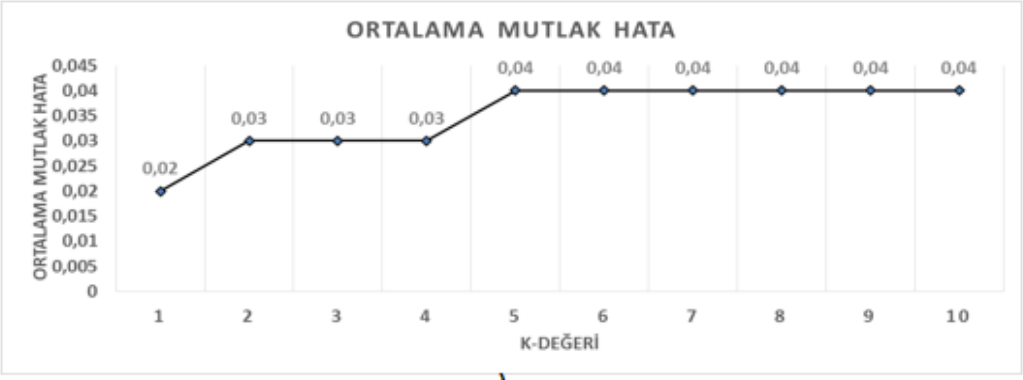


c)

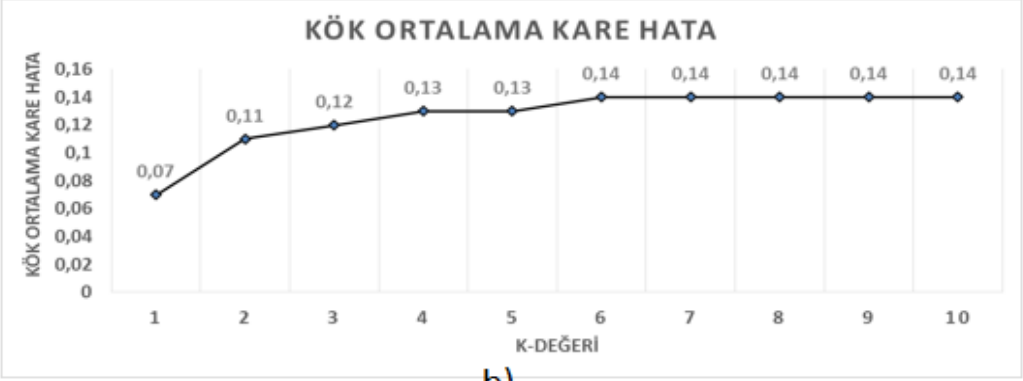


d)

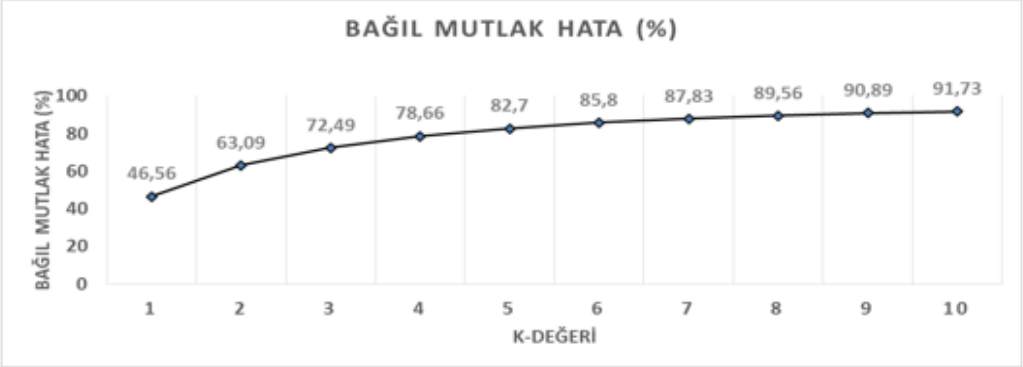
Şekil 4.39.Manhattan uzaklığına ait hata değerleri a)Ortalama mutlak hata b)Kök ortalama kare hata c)Bağıl mutlak hata d)Kök bağıl kare hata.



a)



b)



c)



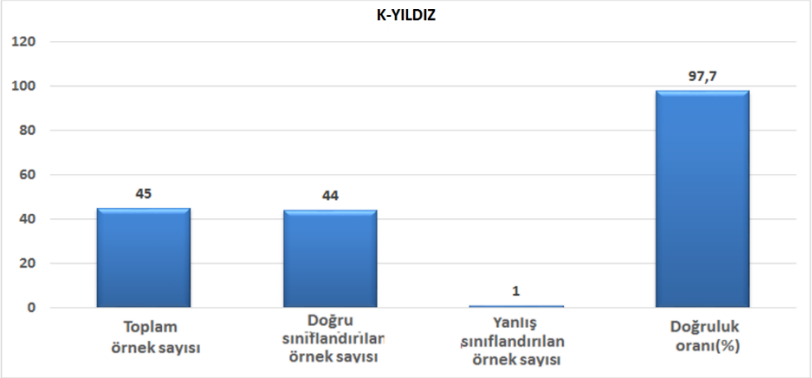
d)

Şekil 4.40. Minkowski uzaklığına ait hata değerleri a)Ortalama mutlak hata b)Kök ortalama kare hata c)Bağıl mutlak hata d)Kök bağıl kare hata.

Sıvı çözeltilerindeki alkol konsantrasyonu bulmada K-EYK algoritmasına kullanımı en çok tercih edilen ağırlık değeri atama yöntemi, her bir komşunun ağırlığının *1/d* olarak alınan yöntemdir. Burada *d,* komşular arası uzaklığıdır. Bu yöntem verilere uygulandığında sıvı tanıma bütün *k* değerleri ve farklı uzaklık ölçütleri için aynı doğruluk değerine sahip olduğu görülmüştür. Yani ağırlıklandırma uygulaması ile algoritmanın performansı *k* değerinden ve uzaklık ölçütünden bağımsız hale gelmiş ve başarı oranı artmıştır. Ağırlıklandırma uygulaması ile sıvı tanımada algoritma bütün uzaklık ölçütleri ve *k* değerlerinde 45 sıvıdan 44 tanesini doğru tahmin ederek %97,7 doğruluk değerine ulaşmıştır.

4.2.1.7 K-Yıldız Algoritması ile Tehlikeli Sıvı Konsantrasyonu Tespiti

K-Yıldız algoritması da yine başarılı algoritmalardan biri olmuştur. Bu algoritma ile 45 adet sıvıdan sadece 1 tane sıvının konsantrasyonunu yanlış tahmin edilmiş ve %97,7 doğruluk oranı elde edilmiştir. Algoritma ile tahmin edilen sıvı sayıları ve doğruluk oranını gösteren grafik Şekil 4.41'de verilmiştir.



Şekil 4.41.K-Yıldız ile tehlikeli sıvı konsantrasyonu bulma.

Sıvı tanımada kullanılan bir diğer performans ölçütü de algoritmanın bu tanıma işlemini yaparken hangi hata oranı ile bu sonuca ulaştığının belirlenmesidir. Kullanılan algoritmaların sıvı tanıma için hesapladığı ortalama mutlak hata, kök ortalama kare hata, bağıl ortalama kare hata ve kök bağıl kare hata değerleri Çizelge 4.26'te verilmiştir.

Çizelge 4.27. Algoritmaların tehlikeli sıvı konsantrasyonu bulmadaki hata değerleri.

Algoritma	Ortalama mutlak hata	Bağıl mutlak hata (%)	Kök ortalama kare hata	Kök bağıl kare hata (%)
Naive Bayes	0,001	2,28	0,02	15,12
DDA	0,001	2,28	0,02	15,12
KDA	0,001	2,28	0,02	15,12
DVM	0,38	79,95	0,19	126,51
SMO	0,04	97,75	0,15	98,12
K-EYK	0,002	46,56	0,07	47,56
K-YILDIZ	0,001	2,28	0,02	15,12

Naive Bayes, DDA, KDA ve K-Yıldız algoritmalarının aynı hata değerini verdikleri ve bu hata değerlerinin DVM ve SMO algoritmalarının hata değerlerinde daha düşük olduğu görülmektedir.

BÖLÜM 5

5 SONUÇLAR VE TARTIŞMA

Bu tezde gündelik sıvılar arasından patlayıcı yapımında kullanılan sıvıların tespiti ve sulu çözeltilerindeki konsantrasyonlarının belirlenmesi için bir mikrodalga ölçüm sistemi önerilmiştir. Önerilen sistem sıvıların içinde bulundukları kaptan çıkarılmadan sıvıya müdahale edilmeden, tahribatsız ve uzaktan ölçüm yapabilen bir sistemdir. Önerilen ölçüm sistemi ile en iyi sıvı tanıma yapabilen algoritmayı tespit etmek için algoritmaların performansları karşılaştırılmıştır. Karşılaştırmada kullanılan performans ölçütleri doğruluk oranı, duyarlılık, hassasiyet, f-ölçütü, Kappa istatistiği ve hata ölçütleridir. Performans karşılaştırması yapılırken hem eğitim seti kullanılarak yapılan sınıflandırma performansı hem de çapraz doğrulamadaki sınıflandırma performansı karşılaştırılmıştır. Bunun yapılmasının nedeni algoritmaların sadece veri tabanında bulunan sıvıların sınıflandırma performanslarını incelemeyip aynı zamanda veri tabanında bulunmayan sıvıların doğru tespitindeki başarılarını da karşılaştırabilmektir. Tehlikeli sıvıların tespitinde Naive Bayes algoritması eğitimde 69 sıvıyı doğru sınıflandırırken çapraz doğrulamada 67 sıvıyı doğru sınıflandırmıştır. Bu algoritmanın eğitimdeki başarı oranı %88,3 çapraz doğrulamadaki başarı oranı %87'dir. Eğitimde 69 doğru sıvı tahmini ile %89,6 başarı oranına sahip olan DDA algoritması çapraz doğrulamada 64 sıvıyı doğru tahmin ederek %83,1 doğruluk oranı elde etmiştir. KDA algoritması ile DDA algoritması eğitim ve çapraz doğrulamada birbirine yakın doğruluk değeri vermiştir. KDA algoritmasının eğitimdeki doğru tahmin sayısı 70, doğruluk oranı %90,9 dur. Çapraz doğrulamada doğru tahmin sayısı 67 doğruluk yüzdesi de %87'dir. SMO algoritması eğitimde ve çapraz doğrulamada aynı doğru tahmin sayısı ve aynı

doğruluk oranına sahip olan tek algoritma olmuştur. Algoritmanın doğru sayısı 67, doğruluk yüzdesi de %87'dir. K-Yıldız algoritması eğitimde diğer algoritmalara göre oldukça iyi bir performans göstererek sadece 1 tane sıvıyı yanlış sınıflandırmış ve %98,7 ile en yüksek doğruluk yüzdesine sahip algoritma olmuştur. Fakat K-yıldız algoritması aynı başarıyı çapraz doğrulamada gösterememiştir. Çapraz doğrulamada algoritma 60 tane sıvıyı doğru tahmin ederek %77,9 doğruluk yüzdesi elde etmiştir. Bu durum algoritmanın veri tabanında bulunmayan sıvıları tahmin etmede başarılı olmadığını göstermektedir. DVM algoritması kullanılan algoritmalar arasında hiçbir tehlikeli sıvıyı doğru tahmin edemeyerek en kötü performansı sergileyen algoritma olmuştur. Algoritmanın doğruluk oranı % 53'tür. Fakat bu algoritmanın kullanımında çekirdek fonksiyon seçimi algoritmanın başarısını önemli ölçüde etkilemektedir. Bu etkiyi incelemek için farklı çekirdek fonksiyonları ile yapılan sınıflandırma çalışmalarından çekirdek fonksiyonun doğrusal ya da polinomal seçilmesi durumunda algoritmanın Sigmoid fonksiyonu ile doğru tahmin ettiği sıvı sayısının 53'ten 69'a doğruluk yüzdesi de %68,8'den %88,3'e çıktığı görülmüştür. K-EYK algoritması hem eğitimde hem de çapraz doğrulamada en fazla doğru sayısı ve doğruluk oranına sahip olan algoritma olmuştur. Algoritma eğitimde sadece 1 tane sıvıyı, çapraz doğrulamada ise 9 tane sıvıyı yanlış sınıflandırarak eğitimde %98,7, çapraz doğrulamada %88,3 doğruluk oranına sahip algoritma olmuştur. Bu algoritmanın başarısına etki eden parametreleri incelemek için farklı uzaklık ölçütleri, *k*- değeri ve ağırlıklandırma uygulaması kullanılarak bunların algoritma performansını nasıl etkilendiği incelenmiştir. Yapılan sınıflandırmalar sonucunda tüm uzaklık ölçütlerinde *k* değerinin artması ile hem eğitimde hem de çapraz doğrulamada algoritmanın doğru tahmin ettiği sıvı sayısı ve buna bağlı olarak doğruluk oranında bir azalım görülmüştür. Fakat ağırlıklandırma uygulaması ile algoritmanın doğruluk oranının *k* değerinden bağımsız hale geldiği gözlenmiştir. Algoritma seçilen tüm *k* değerleri için *k*:1 değerinin verdiği doğruluk oranını verdiği görülmüştür. Algoritmaların diğer performans metrikleri incelendiğinde eğitimde en yüksek duyarlık değeri 0,98 değeri ile K-EYK ve K-Yıldız algoritmalarına aittir. Bu değeri 0,92 değeri ile KDA ve 0,88 değeri ile Naive Bayes algoritması takip ederken en düşük duyarlık değeri 0,87 ile SVM algoritmasına aittir. DVM algoritması ise hiçbir tehlikeli sıvıyı doğru sınıflandıramadığı için duyarlılık değeri hesaplanamamıştır. Algoritmaların hassasiyet değeri de duyarlılık ve f-skoru değeri ile uyumludur. En düşük hassasiyet değeri olan 0,68

değeri DVM algoritması ile elde edilmiştir. Algoritmaların Kappa istatistik değerleri incelendiğinde en düşük Kappa değeri DVM algoritması ile en yüksek Kappa değeri ise hem eğitimde hem de çapraz doğrulamada K-EYK algoritması ile elde edildiği görülmüştür. .K-EYK algoritmasının Kappa değeri eğitimde 0,97 ve çapraz doğrulamada 0,71' dir. Çapraz doğrulamada bütün algoritmaların duyarlılık, hassasiyet, f-ölçütü ve Kappa değeri eğitimden daha düşük olmuştur. En düşük değerlere sahip olan DVM algoritması farklı çekirdek fonksiyon kullanımı ile duyarlılık hassasiyet değeri 0,88 değerine ulaşmıştır. Algoritmaların tehlikeli sıvı tespitinde tahminleri ne kadar doğruluk ile bulduklarını belirlemek için 4 farklı hata ölçütü kullanılmıştır. Bunlar KOKH, OMH, BMH ve KBKH değerleridir. En düşük hata oranı K-EYK algoritmasına aittir. K-EYK algoritmasının eğitimde hata değerleri KOKH 0.08, OMH 0,02, BMH 5,72, KBKH 17,58 çapraz doğrulamada KOKH 041, OMH 0,19, BMH 44,18 ve KBKH değeri 89,06 dir. DVM algoritması da hem eğitimde hem de çapraz doğrulamada KOKH 0,55, OMH 0,31, BMH 120,32 ve KBKH 0,55 hata değerleri ile en yüksek hata değerine ulaşmıştır. K-EYK algoritmasının performansına etki eden parametreleri incelemek amacıyla farklı uzaklık ölçütleri ve k değeri kullanıldığında eğitimde bütün uzaklık ve hata ölçütlerinde *k* değerinin artması ile hata değerinin arttığı fakat çapraz doğrulamada hata değerlerinin *k* değerinin artması ile azaldığı gözlenmiştir.

Çözelti içerisindeki tehlikeli sıvı konsantrasyonu belirlemek için yapılan sınıflandırma çalışmalarında Naive Bayes, DDA, KDA K-EYK ve K-Yıldız algoritmaları % 97.7 doğruluk değerine ulaşırken DVM ve SMO algoritmalarının doğruluk değerleri sırasıyla % 22.2 ve % 44.4 'olmuştur. Naive Bayes, DDA, KDA K-EYK ve K-Yıldız algoritmaları kullanılarak yapılan tanıma çalışmasında sadece gerçek sınıfı %40 isopropanol konsantrasyonuna sahip sıvı saf metanol bulunarak yanlış tahmin yapılmıştır. En düşük doğruluk oranı ise 22,2 olan DVM algoritmasının Radyal temel çekirdek fonksiyon kullanımı ile elde edilmiştir. Algoritma 10 tane sıvının konsantrasyonunu yanlış tahmin etmiştir. DVM algoritmasının doğruluk oranı polinomal fonksiyon kullanımı ile % 82,2' ye çıkmıştır. Öte yandan, Sigmoid fonksiyonunun kullanımı ile %6,6' ya düşmüştür. K-EYK algoritmasında hem eğitimde hem de çapraz doğrulamada *k* değerinin artması doğru tahmin edilen sıvı sayısı ve doğruluk oranının düşmesine neden olmaktadır. Hata oranları da *k* değerinin artması ile artmaktadır. Ağırlıklandırma uygulaması ile algoritmanın doğru tahmin ettiği sıvı sayısı *k* değerinden bağımsız bir hale

gelmiş ve doğruluk oranı tüm *k* değeri ve uzaklık ölçütleri için %97,7 oranına ulaşmaktadır. Algoritmaların genel hata değerleri karşılaştırıldığında en düşük OMH değeri Naive Bayes, DDA, KDA, K-Yıldız algoritmalarında 0,001 değerine sahip olduğu en yüksek OMH değeri olan 0,38 değerine DVM algoritması sahip olduğu görülmüştür. BMH değeri 2,28' dir ve Naive Bayes, DDA, KDA, K-Yıldız algoritmalarında bu hata değeri elde edilmiştir. En yüksek değer olan 97,75 değeri de SMO algoritması tarafından elde edilmiştir. En yüksek KOKH değerini veren algoritma ise 0,19 değeri ile DVM algoritması olmuştur. KBKH hata değerin de de en yüksek değer 126,51 değeri ile DVM algoritmasınındır.

Hem tehlikeli sıvı tespitinde hem de tehlikeli sıvı türü ve konsantrasyon tespitinde yapılan performans değerlendirmesi sonucunda en düşük performansı DVM algoritması ile ede edildiği görülmüştür. Bunun mikrodalga ölçüm verilerinin türünden kaynaklandığı düşünülmektedir. Bu algoritmanın başarısını etkileyen en büyük faktör çekirdek fonksiyon seçimidir. Mikrodalga verilerinin sınıflandırılmasında Polinomal fonksiyon kullanımı ile algoritma algoritmanın performansı arttırılabilir. En yüksek performansı gösteren algoritmanın K-EYK algoritması olduğu görülmüştür. Bu nedenle önerilen ölçüm sistemi ile sıvı tanımada K-EYK algoritmasında ağırlıklandırma uygulaması yapılarak kullanımının yüksek doğruluk sağlayacağı anlaşılmıştır. Yapılan sıvı tespit çalışmalarında sıvılar aynı tür kapta ve aynı sıcaklıktadır. Bundan sonraki çalışmalarda farklı tür kaplarda ve farklı sıcaklıklarda bulunan sıvılar ile sıvı tanıma yapılması düşünülmektedir. Önerilen sistem henüz başlangıç aşamasındadır. Ölçüm sisteminde kullanılan VNA yerine bir devre tasarlanıp K-EYK algoritmasının da gömülü olduğu otomatik sıvı tarama sistemi geliştirilebilir. Bir grup saha testi gerçekleştirdikten sonra, K-EYK tabanlı prototip sistemi havaalanı, konser salonları, AVM vb. kalabalık yerlerde güvenlik kontrol noktalarında sıvı tarama sistemi olarak kullanılabilir. Sıvı tespit süresi oldukça kısa olan bu sistem kullanımı ile insanların vaktini almadan ve uzun sıralar oluşturmadan kolayca sıvı kontrolü yapılabilir.

KAYNAKLAR

Aci, M., & Avci, M. (2011). K nearest neighbor reinforced expectation maximization method. *Expert Systems with Applications, 38*(10), 12585-12591.

Akbaba, S. Ö. Y., & Atakan, C. T. D. (2005). *Karesel Diskriminant Analizi Ve Hata Oranlari Tahmini.* Ankara Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dali,

Åkeson, M., Nordberg, M., Ehlerding, A., Nilsson, L.-E., Östmark, H., & Strömbeck, P. (2011). *Picosecond laser pulses improves sensitivity in standoff explosive detection.* Paper presented at the Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XVI.

Akpınar, H. (2014). *Data: Veri madenciliği veri analizi*: Papatya Yayıncılık Eğitim.

Al-Mously, S. I. Y. (2012). A modified complex permittivity measurement technique at microwave frequency. *International Journal of New Computer Architectures and Their Applications, 2*(2), 389-402.

Almaviva, S., Angelini, F., Chirico, R., Palucci, A., Nuvoli, M., Schnuerer, F., . . . Romolo, F. (2014). *Eye-safe UV Raman spectroscopy for proximal detection of explosives and their precursors in fingerprints concentration.* Paper presented at the Optics and Photonics for Counterterrorism, Crime Fighting, and Defence X; and Optical Materials and Biomaterials in Security and Defence Systems Technology XI.

Almaviva, S., Botti, S., Cantarini, L., Palucci, A., Puiu, A., Rufoloni, A., . . . Romolo, F. (2012). *Trace detection of explosives by surface enhanced Raman spectroscopy.* Paper presented at the Optics and Photonics for Counterterrorism, Crime Fighting, and Defence Viii.

Athey, T. W., Stuchly, M. A., & Stuchly, S. S. (1982). Measurement of radio frequency permittivity of biological tissues with an open-ended coaxial line: Part I. *IEEE Transactions on Microwave Theory and Techniques, 30*(1), 82-86.

Baker, G. A., & Moore, D. S. (2005). Progress in plasmonic engineering of surface-enhanced Raman-scattering substrates toward ultra-trace analysis. *Analytical and bioanalytical chemistry, 382*(8), 1751-1770.

Balanis, C. A. (2016). *Antenna theory: analysis and design*: John wiley & sons.

Baldi, P., Brunak, S., Chauvin, Y., Andersen, C. A., & Nielsen, H. (2000). Assessing the accuracy of prediction algorithms for classification: an overview. *Bioinformatics, 16*(5), 412-424.

Barber, J., Weatherall, J. C., Smith, B. T., Duffy, S., Goettler, S. J., & Krauss, R. A. (2010). *Millimeter wave measurements of explosives and simulants.* Paper presented at the Passive Millimeter-Wave Imaging Technology XIII.

Baxter, J. (2000). A model of inductive bias learning. *Journal of artificial intelligence research, 12*, 149-198.

Bermejo, P., Gámez, J. A., & Puerta, J. M. (2011). Improving the performance of Naive Bayes multinomial in e-mail foldering by introducing distribution-based balance of datasets. *Expert Systems with Applications, 38*(3), 2072-2080.

Bertozzi, W., & Ledoux, R. J. (2005). Nuclear resonance fluorescence imaging in non-intrusive cargo inspection. *Nuclear Instruments and Methods in Physics Research Section B: Beam Interactions with Materials and Atoms, 241*(1-4), 820-825.

Bertsekas, D. P., & Tsitsiklis, J. N. (1995). *Neuro-dynamic programming: an overview.* Paper presented at the Proceedings of 1995 34th IEEE Conference on Decision and Control.

Bingham, A. L., Lucey, P. G., Akagi, J. T., Hinrichs, J. L., & Knobbe, E. T. (2014). *LWIR hyperspectral micro-imager for detection of trace explosive particles.* Paper presented at the Next-Generation Spectroscopic Technologies Vii.

Blum, A., & Mitchell, T. (1998). *Combining labeled and unlabeled data with co-training.* Paper presented at the Proceedings of the eleventh annual conference on Computational learning theory.

Botti, S., Cantarini, L., Almaviva, S., Puiu, A., & Rufoloni, A. (2014). Assessment of SERS activity and enhancement factors for highly sensitive gold coated substrates probed with explosive molecules. *Chemical Physics Letters, 592*, 277-281.

Bremer, M. T., & Dantus, M. (2013). Standoff explosives trace detection and imaging by selective stimulated Raman scattering. *Applied Physics Letters, 103*(6), 061119.

Bremer, M. T., Wrzesinski, P. J., Butcher, N., Lozovoy, V. V., & Dantus, M. (2011). Highly selective standoff detection and imaging of trace chemicals in a complex background using single-beam coherent anti-Stokes Raman scattering. *Applied Physics Letters, 99*(10), 101109.

Brownlee, J. (2014). Classification accuracy is not enough: More performance measures you can use. *Machine Learning Mastery, 21*.

Büttner, F., Hagemann, J., Wellhausen, M., Funke, S., Lenth, C., Rotter, F., . . . Strube, M. (2013). *Surface enhanced vibrational spectroscopy for the detection of explosives.* Paper presented at the Electro-Optical and Infrared Systems: Technology and Applications X.

Carasco, C., Perot, B., Bernard, S., Mariani, A., Szabo, J.-L., Sannie, G., . . . Viesti, G. (2008). In-field tests of the EURITRACK tagged neutron inspection system. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 588*(3), 397-405.

Caruana, R. (1993). Multitask Learning: A Knowledge-Based Source of Inductive Bias ICML. *Google Scholar Google Scholar Digital Library Digital Library*.

Chapelle, O., Scholkopf, B., & Zien, A. (2009). Semi-supervised learning (chapelle, o. et al., eds.; 2006)[book reviews]. *IEEE Transactions on Neural Networks, 20*(3), 542-542.

Chen, L.-F., Ong, C., Neo, C., Varadan, V., & Varadan, V. K. (2004). *Microwave electronics: measurement and materials characterization*: John Wiley & Sons.

Clark, T. R., McKenna, T. P., & Nanzer, J. A. (2015). *Photonic millimeter wave system for high capacity wireless communications.* Paper presented at the 2015 IEEE MTT-S International Microwave Symposium.

Cleary, J. G., & Trigg, L. E. (1995). K*: An instance-based learner using an entropic distance measure. In *Machine Learning Proceedings 1995* (pp. 108-114): Elsevier.

Crespy, C., Duvauchelle, P., Kaftandjian, V., Soulez, F., & Ponard, P. (2010). Energy dispersive X-ray diffraction to identify explosive substances: Spectra analysis procedure optimization. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 623*(3), 1050-1060.

Diaz, D., & Hahn, D. W. (2020). Raman spectroscopy for detection of ammonium nitrate as an explosive precursor used in improvised explosive devices. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 118204.

Dicken, A., Rogers, K., Evans, P., Rogers, J., & Chan, J. W. (2010). The separation of X-ray diffraction patterns for threat detection. *Applied Radiation and Isotopes, 68*(3), 439-443.

Doad, P., & Bartere, M. (2013). A Review: Study of Various Clustering Techniques. *International Journal of Engineering Research & Technology*, *2*(11), 3141-3145.

Dogariu, A. (2013). *Standoff detection and imaging of explosives using CARS.* Paper presented at the CLEO: Applications and Technology.

Dong, Q., Yu, C., Li, L., Nie, L., Li, D., & Zang, H. (2019). Near-infrared spectroscopic study of molecular interaction in ethanol-water mixtures. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 222*, 117183.

Dubroca, T., Brown, G., & Hummel, R. E. (2014). Detection of explosives by differential hyperspectral imaging. *Optical Engineering, 53*(2), 021112.

Dubroca, T., Guetard, G., & Hummel, R. E. (2012). *Influence of spatial differential reflection parameters on 2, 4, 6-trinitrotoluene (TNT) absorption spectra.* Paper presented at the Chemical, Biological, Radiological, Nuclear, and Explosives (CBRNE) Sensing XIII.

Dubroca, T., Moyant, K., & Hummel, R. E. (2013). Ultra-violet and visible absorption characterization of explosives by differential reflectometry. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 105*, 149-155.

Eilbert, R. F., & Krug, K. D. (1992). *Dual Energy X-Ray Scanner for Detecting Contraband.* Paper presented at the Contraband and Cargo Inspection Technology International Symposium Proceedings.

Eilbert, R. F., & Krug, K. D. (1993). *Aspects of image recognition in vivid technologies' dual-energy x-ray system for explosives detection.* Paper presented at the Applications of Signal and Image Processing in Explosives Detection Systems.

Espy, M., Flynn, M., Gomez, J., Hanson, C., Kraus, R., Magnelind, P., . . . Owens, T. (2010). Ultra-low-field MRI for the detection of liquid explosives. *Superconductor Science and Technology, 23*(3), 034023.

Flinton, G., & Sejnowski, T. (1999). Unsupervised learning and map formation: Foundations of neural computation. In: MIT Press.

Fountain, A. W., Christesen, S. D., Moon, R. P., Guicheteau, J. A., & Emmons, E. D. (2014). Recent advances and remaining challenges for the spectroscopic detection of explosive threats. *Applied spectroscopy, 68*(8), 795-811.

Fu, W.-T., & Anderson, J. R. (2006). From recurrent choice to skill learning: A reinforcement-learning model. *Journal of experimental psychology: General, 135*(2), 184.

Gares, K. L., Hufziger, K. T., Bykov, S. V., & Asher, S. A. (2016). Review of explosive detection methodologies and the emergence of standoff deep UV resonance Raman. *Journal of Raman Spectroscopy, 47*(1), 124-141.

Gasser, C., Göschl, M., Ofner, J., & Lendl, B. (2019). Stand-off Hyperspectral Raman Imaging and Random Decision Forest Classification: A Potent Duo for the Fast, Remote Identification of Explosives. *Analytical chemistry, 91*(12), 7712-7718.

Gavenda, T., & Křesálek, V. (2013). *Terahertz time-domain spectroscopy for distinguishing different kinds of gunpowder.* Paper presented at the Millimetre Wave and Terahertz Sensors and Technology Vi.

George, G., Edwards, C. S., Hayes, J. I., Yu, L., Ede, S. R., Wen, J., & Luo, Z. (2019). A novel reversible fluorescent probe for the highly sensitive detection of nitro and peroxide organic explosives using electrospun BaWO 4 nanofibers. *Journal of Materials Chemistry C, 7*(47), 14949-14961.

Gillibert, R., Huang, J. Q., Zhang, Y., Fu, W. L., & de la Chapelle, M. L. (2018). Explosive detection by surface enhanced raman scattering. *TrAC Trends in Analytical Chemistry, 105*, 166-172.

Glimtoft, M., Bååth, P., Saari, H., Mäkynen, J., Näsilä, A., & Östmark, H. (2014). *Towards eye-safe standoff Raman imaging systems.* Paper presented at the Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XIX.

Gradišek, A., & Apih, T. (2010). NMR-based liquid explosives detector. *Applied Magnetic Resonance, 38*(4), 485-493.

Greenberg, J. A., & Brady, D. J. (2014). *Structured illumination for compressive x-ray diffraction tomography.* Paper presented at the Computational Imaging Xii.

Greenberg, J. A., Krishnamurthy, K., & Brady, D. (2013). Snapshot molecular imaging using coded energy-sensitive detection. *Optics express, 21*(21), 25480-25491.

Gudmundson, E., Jakobsson, A., Poplett, I. J., & Smith, J. A. (2009). *Detection and classification of liquid explosives using NMR.* Paper presented at the 2009 IEEE International Conference on Acoustics, Speech and Signal Processing.

Gulati, K. K., Gambhir, T., Kumar, N., & Gambhir, V. (2019). Standoff detection of liquid explosives and hazardous chemicals concealed in translucent plastic bottles using nanoseconds time gated Raman spectroscopy. *Defence Science Journal, 69*(4), 342.

Haddadi, K., Wang, M., Benzaim, O., Glay, D., & Lasri, T. (2008). Contactless microwave technique based on a spread-loss model for dielectric materials characterization. *IEEE Microwave and Wireless Components Letters, 19*(1), 33-35.

Hamad, S., Podagatlapalli, G. K., Mohiddon, M. A., & Rao, S. V. (2015). Surface enhanced fluorescence from corroles and SERS studies of explosives using copper nanostructures. *Chemical Physics Letters, 621*, 171-176.

Harding, G. (2009). X-ray diffraction imaging—a multi-generational perspective. *Applied Radiation and Isotopes, 67*(2), 287-295.

Harding, G., Fleckenstein, H., Kosciesza, D., Olesinski, S., Strecker, H., Theedt, T., & Zienert, G. (2012). X-ray diffraction imaging with the Multiple Inverse Fan Beam topology: Principles, performance and potential for security screening. *Applied radiation and isotopes, 70*(7), 1228-1237.

Hatab, N. A., Eres, G., Hatzinger, P. B., & Gu, B. (2010). Detection and analysis of cyclotrimethylenetrinitramine (RDX) in environmental samples by surface-enhanced Raman spectroscopy. *Journal of Raman Spectroscopy, 41*(10), 1131-1136.

Holthoff, E. L., Stratis-Cullum, D. N., & Hankus, M. E. (2011). A nanosensor for TNT detection based on molecularly imprinted polymers and surface enhanced Raman scattering. *Sensors, 11*(3), 2700-2714.

Huang, T.-M., Kecman, V., & Kopriva, I. (2006). *Kernel based algorithms for mining huge data sets* (Vol. 1): Springer.

Itozaki, H. (2009). Nuclear quadrupole resonance for explosive detection. In *Anti-personnel Landmine Detection for Humanitarian Demining* (pp. 147-155): Springer.

Izadi, B., Ranjbarian, B., Ketabi, S., & Nassiri-Mofakham, F. (2013). Performance analysis of classification methods and alternative linear programming integrated with fuzzy delphi feature selection. *International Journal of Information Technology and Computer Science (IJITCS), 5*(10), 9.

Jamil, A. K., Izake, E. L., Sivanesan, A., & Fredericks, P. M. (2015). Rapid detection of TNT in aqueous media by selective label free surface enhanced Raman spectroscopy. *Talanta, 134*, 732-738.

Joshi, R. (2016). Accuracy, precision, recall & f1 score: Interpretation of performance measures. *Retrieved April, 1*(2018), 2016.

Kalinin, V., Evsenin, A., Kuznetsov, A., Osetrov, O., Vakhtin, D., Yurmanov, P., & Gorshkov, I. (2008). Detector of hazardous substances based on nanosecond neutron analysis. In *Detection of Liquid Explosives and Flammable Agents in Connection with Terrorism* (pp. 71-78): Springer.

Kartal, E. (2015). Sınıflandırmaya dayalı makine öğrenmesi teknikleri ve kardiyolojik risk değerlendirmesine ilişkin bir uygulama. *Ulusal Tez Merkezi*(394514).

Kehres, J., Lyksborg, M., & Olsen, U. L. (2017). *Threat detection of liquid explosives and precursors from their x-ray scattering pattern using energy dispersive detector technology.* Paper presented at the Radiation Detectors in Medicine, Industry, and National Security XVIII.

Khan, M. T., & Ali, S. M. (2012). A brief review of measuring techniques for characterization of dielectric materials. *International Journal of Information Technology and Electrical Engineering, 1*(1).

Kramers, H. A. (1923). XCIII. On the theory of X-ray absorption and of the continuous X-ray spectrum. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science, 46*(275), 836-871.

Krylatykh, N. A., Yakh'ya, V. F., Fakhrutdinov, A. R., Anashkin, V. N., Shagalov, V. A., & Khabipov, R. S. (2016). Detection of explosive precursors using low-field magnetic resonance imaging. *Applied Magnetic Resonance, 47*(8), 915-924.

Li, Z., Haigh, A., Soutis, C., Gibson, A., & Sloan, R. (2017). Evaluation of water content in honey using microwave transmission line technique. *Journal of Food Engineering, 215*, 113-125.

Littman, M., & Moore, A. (1996). Reinforcement Learning: A Survey, Journal of Artificial Intelligence Research 4. In: syf.

Loeffen, P. W., Maskall, G., Bonthron, S., Bloomfield, M., Tombling, C., & Matousek, P. (2016). *The performance of spatially offset Raman spectroscopy for liquid explosive detection.* Paper presented at the Optics and Photonics for Counterterrorism, Crime Fighting, and Defence XII.

Lopez-Lopez, M., & Garcia-Ruiz, C. (2014). Infrared and Raman spectroscopy techniques applied to identification of explosives. *TrAC Trends in Analytical Chemistry, 54*, 36-44.

Lucey, S., & Ashraf, A. B. (2013). Nearest neighbor classifier generalization through spatially constrained filters. *Pattern recognition, 46*(1), 325-331.

Madden, R. W., Mahdavieh, J., Smith, R. C., & Subramanian, R. (2008). *An explosives detection system for airline security using coherent x-ray scattering technology.* Paper presented at the Hard X-Ray, Gamma-Ray, and Neutron Detector Physics X.

Maestrojuan, I., Palacios, I., Etayo, D., Iriarte, J., Teniente, J., Ederra, I., & Gonzalo, R. (2011). *Explosives characterization in terahertz range.* Paper presented at the Millimetre Wave and Terahertz Sensors and Technology Iv.

Mahmoud, K. A., & Zourob, M. (2013). Fe 3 O 4/Au nanoparticles/lignin modified microspheres as effectual surface enhanced Raman scattering (SERS) substrates for highly selective and sensitive detection of 2, 4, 6-trinitrotoluene (TNT). *Analyst, 138*(9), 2712-2719.

McFee, J., Faust, A., & Pastor, K. (2013). Photoneutron spectroscopy using monoenergetic gamma rays for bulk explosives detection. *Nuclear Instruments*

and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 704, 131-139.

Moore, D. S., McGrane, S. D., Greenfield, M. T., & Scharff, R. J. (2012). *Optimal coherent control methods for explosives detection.* Paper presented at the Micro- and Nanotechnology Sensors, Systems, and Applications Iv.

Moore, D. S., Rabitz, H., McGrane, S., Greenfield, M., Scharff, R., Chalmers, R., & Roslund, J. (2011). *Optimal dynamic detection of explosives.* Paper presented at the Chemical, Biological, Radiological, Nuclear, and Explosives (CBRNE) Sensing XII.

O'Flynn, D., Reid, C., Christodoulou, C., Wilson, M., Veale, M., Seller, P., . . . Speller, R. (2013). Explosive detection using pixellated X-ray diffraction (PixD). *Journal of Instrumentation, 8*(03), P03007.

Obhodas, J., Sudac, D., Valkovic, V., Baricevic, M., Franulović, A., Perot, B., . . . El Kanawati, W. (2010). Analysis of containerized cargo in the ship container terminal. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 619*(1-3), 460-466.

Orachorn, P., Chankow, N., & Srisatit, S. (2017). Development of technique for screening liquids in glass bottle using low energy X-ray transmission. *RMUTT Research Journal Rajamangala University of Technology Thanyaburi, 16*(1-2), 20-26.

Özkan, Y. (2008). *Veri madenciliği yöntemleri*: Papatya Yayıncılık Eğitim.

Palka, N., Szustakowski, M., Kowalski, M., Trzcinski, T., Ryniec, R., Piszczek, M., . . . Wrobel, J. (2012). *THz spectroscopy and imaging in security applications.* Paper presented at the 2012 19th International Conference on Microwaves, Radar & Wireless Communications.

Patsaeva, S., Dolenko, T., Burikov, S., & Yuzhakov, V. (2014). Remote measurements of concentration of organic solvents in binary mixtures using Raman spectroscopy. *Atmospheric and Oceanic Optics, 27*(4), 291-296.

Piramuthu, S., & Sikora, R. T. (2009). Iterative feature construction for improving inductive learning algorithms. *Expert Systems with Applications, 36*(2), 3401-3406.

Platt, J. (1998). Sequential minimal optimization: A fast algorithm for training support vector machines.

Podagatlapalli, G. K., Hamad, S., Mohiddon, M. A., & Rao, S. V. (2014). Effect of oblique incidence on silver nanomaterials fabricated in water via ultrafast laser ablation for photonics and explosives detection. *Applied surface science, 303*, 217-232.

Portnov, A., Bar, I., & Rosenwaks, S. (2010). Highly sensitive standoff detection of explosives via backward coherent anti-Stokes Raman scattering. *Applied Physics B, 98*(2-3), 529-535.

Rammah, A., Zakaria, Z., Ruslan, E., & Isa, A. (2015). Comparative study of materials characterization using microwave resonators. *Aust. J. Basic Appl. Sci, 9*(1), 76-85.

Raza, A., & Saha, B. (2014). In situ silver nanoparticles synthesis in agarose film supported on filter paper and its application as highly efficient SERS test stripes. *Forensic science international, 237*, e42-e46.

Rocha, L. S., Junqueira, C. C., Gambin, E., Vicente, A. N., Culhaoglu, A. E., & Kemptner, E. (2013). *A free space measurement approach for dielectric material characterization.* Paper presented at the 2013 SBMO/IEEE MTT-S International Microwave & Optoelectronics Conference (IMOC).

Saeed, K., Shafique, M. F., Byrne, M. B., & Hunter, I. C. (2012). Planar microwave sensors for complex permittivity characterization of materials and their applications. *Applied Measurement Systems*, 319-350.

Sangün, L. (2007). Temel bileşenler analizi, ayırma analizi, kümeleme analizleri ve ekolojik verilere uygulanması üzerine bir araştırma. *Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Su Ürünleri Anabilim Dalı Doktora Tezi, Adana 12s*.

Santillán, J. D., Brown, C. D., & Jalenak, W. (2007). *Advances in Raman spectroscopy for explosive identification in aviation security.* Paper presented at the Optics and Photonics in Global Homeland Security III.

Santos, J. C., Dias, M. H., Aguiar, A. P., Borges Jr, I., & Borges, L. E. (2009). Using the coaxial probe method for permittivity measurements of liquids at high temperatures. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications (JMOe), 8*(1), 78S-91S.

Shannon, C. E. (2001). A mathematical theory of communication. *ACM SIGMOBILE mobile computing and communications review, 5*(1), 3-55.

Shaw, T., Brown, D., D'Arcy, J., Liu, F., Shea, P., Sivakumar, M., & Gozani, T. (2005). Small threat and contraband detection with TNA-based systems. *Applied radiation and isotopes, 63*(5-6), 779-782.

Shea, D. A., & Morgan, D. (2007). *Detection of explosives on airline passengers: Recommendation of the 9/11 Commission and related issues*.

Shearer, C. (2000). The CRISP-DM model: the new blueprint for data mining. *Journal of data warehousing, 5*(4), 13-22.

Shreve, A. P., Cherepy, N. J., & Mathies, R. A. (1992). Effective rejection of fluorescence interference in Raman spectroscopy using a shifted excitation difference technique. *Applied spectroscopy, 46*(4), 707-711.

Skatter, S., Fritsch, S., & Schlomka, J.-P. (2016). *Detecting liquid threats with x-ray diffraction imaging (XDi) using a hybrid approach to navigate trade-offs between photon count statistics and spatial resolution.* Paper presented at the Anomaly Detection and Imaging with X-Rays (ADIX).

Sleiman, J. B., El Haddad, J., Perraud, J., Bassel, L., Bousquet, B., Palka, N., & Mounaix, P. (2014). *Qualitative and quantitative analysis of explosives by terahertz time-domain spectroscopy: application to imaging.* Paper presented at the 2014 39th International Conference on Infrared, Millimeter, and Terahertz waves (IRMMW-THz).

Startsev, M. A., & Elezzabi, A. Y. (2013). Terahertz frequency continuous-wave spectroscopy and imaging of explosive substances. *ISRN Optics, 2013*.

Sturm, B. L. (2013). Classification accuracy is not enough. *Journal of Intelligent Information Systems, 41*(3), 371-406.

Sun, B., Li, M., Zhang, F., Zhong, Y., Kang, N., Lu, W., & Liu, J. (2010). The performance of a fast testing system for illicit materials detection based on energy-dispersive X-ray diffraction technique. *Microchemical Journal, 95*(2), 293-297.

Sun, L. (2013). *Liquid dangerous goods detection based on electronic nose odor recognition technology.* Paper presented at the International Symposium on Photoelectronic Detection and Imaging 2013: Infrared Imaging and Applications.

Sutton, R. S., & Barto, A. G. (1998). *Introduction to reinforcement learning* (Vol. 135): MIT press Cambridge.

Talian, I., & Huebner, J. (2013). Separation followed by direct SERS detection of explosives on a novel black silicon multifunctional nanostructured surface prepared in a microfluidic channel. *Journal of Raman Spectroscopy, 44*(4), 536-539.

Tan, X., Huang, S., Zhong, Y., Yuan, H., Zhou, Y., Xiao, Q., . . . Qi, C. (2017). *Detection and identification of flammable and explosive liquids using THz time-domain spectroscopy with principal component analysis algorithm.* Paper presented at the 2017 10th UK-Europe-China Workshop on Millimetre Waves and Terahertz Technologies (UCMMT).

Tan, X., Tang, S., Yang, Z., Xie, J., Tang, J., Xie, F., & Qi, C. (2018). *Detection and identification of liquids using reflection THz time-domain spectroscopy with principal component analysis and support vector machine algorithm.* Paper presented at the International Symposium on Ultrafast Phenomena and Terahertz Waves.

Tereshchenko, O., Buesink, F. J. K., & Leferink, F. B. J. (2011). *An overview of the techniques for measuring the dielectric properties of materials.* Paper presented at the 2011 XXXth URSI General Assembly and Scientific Symposium.

Thrun, S. (1996). *Is learning the n-th thing any easier than learning the first?* Paper presented at the Advances in neural information processing systems.

Trofimov, V. A., Varentsova, S. A., & Chen, J. (2010). *Identification of explosive using the spectrum dynamics of reflected THz and GHz radiation.* Paper presented at the Millimetre Wave and Terahertz Sensors and Technology Iii.

Trofimov, V. A., Varentsova, S. A., Szustakowski, M., & Palka, N. (2012). *Efficiency of the detection and identification of ceramic explosive using the reflected THz signal.* Paper presented at the Terahertz Physics, Devices, and Systems Vi: Advanced Applications in Industry and Defense.

Ünal, M. (2006). Ayırma analizi ve bir uygulama. In: Gazi Üniversitesi, Fen Bilimleri Enstitüsü.

Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE transactions on neural networks, 10*(5), 988-999.

Vašková, H., & Tomeček, M. (2018). *Rapid spectroscopic measurement of methanol in water-ethanol-methanol mixtures.* Paper presented at the MATEC Web of Conferences.

Wagner, J., Ostendorf, R., Grahmann, J., Merten, A., Hugger, S., Jarvis, J. P., . . . Schenk, H. (2015). *Widely tunable quantum cascade lasers for spectroscopic sensing.* Paper presented at the Quantum Sensing and Nanophotonic Devices Xii.

Walczakowski, M., Palka, N., Szustakowski, M., Czerwinski, A., & Sypek, M. (2013). *Detection of the THz waves from the 5m distance.* Paper presented at the Millimetre Wave and Terahertz Sensors and Technology Vi.

Wells, K., & Bradley, D. (2012). A review of X-ray explosives detection techniques for checked baggage. *Applied radiation and isotopes, 70*(8), 1729-1746.

Whetstone, Z., & Kearfott, K. (2014). A review of conventional explosives detection using active neutron interrogation. *Journal of Radioanalytical and Nuclear Chemistry, 301*(3), 629-639.

Wilke, C. (2005). *Leveraging Technology to Improve Aviation Security, Part II.* Paper presented at the US Congress Hearing, Committee on Homeland Security, Subcommittee on Economic Security, Infrastructure Protection, and Cybersecurity.

Witko, E. M., Buchanan, W. D., & Korter, T. M. (2011). Terahertz spectroscopy and solid-state density functional theory simulations of the improvised explosive oxidizers potassium nitrate and ammonium nitrate. *The Journal of Physical Chemistry A, 115*(44), 12410-12418.

Witko, E. M., & Korter, T. M. (2012). Terahertz spectroscopy of the explosive taggant 2, 3-dimethyl-2, 3-dinitrobutane. *The Journal of Physical Chemistry A, 116*(25), 6879-6884.

Xu, Z., & Meng, X. (2012). Detection of 3-nitro-1, 2, 4-triazol-3-one (NTO) by surface-enhanced Raman spectroscopy. *Vibrational Spectroscopy, 63*, 390-395.

Yin, H. C., Chao, Z. M., & Xu, Y. P. (2005). A new free- space method for measurement of electromagnetic parameters of biaxial materials at microwave frequencies. *Microwave and Optical Technology Letters, 46*(1), 72-78.

Ying, Z., Naidu, R., & Crawford, C. R. (2006). Dual energy computed tomography for explosive detection. *Journal of X-ray Science and Technology, 14*(4), 235-256.

Zachhuber, B., Carrillo- Carrión, C., Simonet Suau, B. M., & Lendl, B. (2012). Quantification of DNT isomers by capillary liquid chromatography using at- line SERS detection or multivariate analysis of SERS spectra of DNT isomer mixtures. *Journal of Raman Spectroscopy, 43*(8), 998-1002.

Zhang, C., Wang, K., Han, D., & Pang, Q. (2014). Surface enhanced Raman scattering (SERS) spectra of trinitrotoluene in silver colloids prepared by microwave heating method. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 122*, 387-391.

Zhang, W., Tang, Y., Shi, A., Bao, L., Shen, Y., Shen, R., & Ye, Y. (2018). Recent developments in spectroscopic techniques for the detection of explosives. *Materials, 11*(8), 1364.

Zhao, B., Wolter, S., & Greenberg, J. A. (2018). *Application of machine learning to x-ray diffraction-based classification.* Paper presented at the Anomaly Detection and Imaging with X-Rays (ADIX) III.

ÖZGEÇMİŞ

2000 yılında girdiği Kocaeli Üniversitesinde 1 yıl İngilizce hazırlık sınıfı okudu. 2001 yılında öğrenime başladığı Jeofizik Mühendisliği bölümünden birincilikle mezun oldu. 2009 yılında, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Jeofizik Mühendisliği Anabilim Dalı'nda Yüksek Lisans öğrenimini tamamladı. 2010 yılında aynı üniversitede başladığı doktora öğrenimini 2016 yılında bitirdi. TÜBİTAK'ta çeşitli projelerde görev aldı. 2020 yılında Yönetim Bilişim Sistemleri Bölümünden mezun oldu. 2015 yılından beri Trakya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği bölümünde ikinci doktorasına devam etmektedir.

TEZ İLE İLGİLİ BİLİMSEL FAALİYETLER

Efeoğlu, E., & Tuna, G. (2020). The Use of Microwave and K* Algorithm in Determination of Alcohol Concentration in Liquids. *Russian Journal of Nondestructive Testing*, *56*(8), 689-697. DOI: https://doi.org/10.1134/S1061830920080033

Efeoğlu, E., & Tuna, G. (2020). Detection of Hazardous Liquids Using Microwave Data and Well-Known Classification Algorithms. *Russian Journal of Nondestructive Testing*, *56*(9), 742–751. DOI: https://doi.org/10.1134/S106183092009003X