

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ DOKTORA
PROGRAMI**

**DERİN AĞ TABANLI ÖZNİTELİKLERLE GAZLARIN
SINIFLANDIRILMASI VE KONSANTRASYON DEĞERLERİNİN
REGRESYON ANALİZİ**

HAZIRLAYAN

HANDE BAKİLER

DOKTORA TEZİ

ANKARA - 2023

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ DOKTORA
PROGRAMI**

**DERİN AĞ TABANLI ÖZNİTELİKLERLE GAZLARIN
SINIFLANDIRILMASI VE KONSANTRASYON DEĞERLERİNİN
REGRESYON ANALİZİ**

HAZIRLAYAN

HANDE BAKİLER

DOKTORA TEZİ

TEZ DANIŞMANI

DOÇ. DR. SELDA GÜNEY

ANKARA - 2023

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı çerçevesinde Hande BAKİLER tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 09 / 01 / 2023

Tez Adı: Derin Ağ Tabanlı Özniteliklerle Gazların Sınıflandırılması ve Konsantrasyon Değerlerinin Regresyon Analizi

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)

İmza

Prof. Dr. Hasan Şakir BİLGE (Başkan), Gazi Üniversitesi

.....

Doç. Dr. Selda GÜNEY (Danışman), Başkent Üniversitesi

.....

Prof. Dr. Sedat NAZLIBİLEK, Başkent Üniversitesi

.....

Doç. Dr. Derya YILMAZ, Gazi Üniversitesi

.....

Dr. Öğr. Üyesi Deniz KARAÇOR, Başkent Üniversitesi

.....

ONAY

Prof. Dr. Faruk ELALDI

Fen Bilimleri Enstitüsü Müdürü

Tarih : ... / ... / 2023

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 16 / 02 / 2023

Öğrencinin Adı, Soyadı: Hande BAKİLER

Öğrencinin Numarası: 21420112

Anabilim Dalı: Elektrik-Elektronik Mühendisliği

Anabilim Dalı Programı: Elektrik-Elektronik Mühendisliği Doktora Programı

Danışmanın Unvanı/Adı, Soyadı: Doç. Dr. Selda GÜNEY

Tez Başlığı: Derin Ağ Tabanlı Özniteliklerle Gazların Sınıflandırılması ve Konsantrasyon Değerlerinin Regresyon Analizi

Yukarıda başlığı belirtilen Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 104 sayfalık kısmına ilişkin, 16 / 02 / 2023 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %10'dur. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: 16 / 02 / 2023

Doç. Dr. Selda Güney

Canım Anneme,



TEŞEKKÜR

Tez çalışmam süresince bana destek olan, yanımda olan, bilgi, birikim ve deneyimlerini esirgemeyen, ışığıyla yolumu aydınlatan değerli tez danışmanım Doç. Dr. Selda GÜNEY'e en içten teşekkürü bir borç bilirim.

Değerli yorum ve önerileriyle tez çalışmalarına katkılarını sunan tez izleme komitesinde yer alan hocalarım Prof. Dr. Hasan OĞUL ve Doç. Dr. Derya YILMAZ'a teşekkürlerimi sunarım.

Tez savunma sınavı jüri üyelerim Prof. Dr. Hasan Şakir BİLGE, Prof. Dr. Sedat NAZLIBİLEK ve Dr. Öğr. Üyesi Deniz KARAÇOR'a değerli katkılarından dolayı teşekkür ederim.

Hayatım boyunca her zaman yanımda olan, desteği, sevgisi, özeni, ilgisi ile bugünlere gelmemde en büyük katkıyı sağlayan, emeği, özverisi paha biçilemez kıymette olan Canım Anneme, sevgisi, ilgisi, desteği için Canım Babama sonsuz teşekkür ederim.

ÖZET

Hande BAKİLER

DERİN AĞ TABANLI ÖZNİTELİKLERLE GAZLARIN SINIFLANDIRILMASI VE KONSANTRASYON DEĞERLERİNİN REGRESYON ANALİZİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2022

Elektronik burun (e-burun), kimyasal sensör dizilimi ile biyolojik malzemelerden yayılan uçucu bileşikler üzerinde hassas ölçümler yaparak çeşitli özellikleri belirleyen, tanımlayan ve sınıflandıran elektronik algılama teknolojisine dayalı bir cihazdır. İnsan koku alma mekanizmasını taklit ederek çalışan bu sistemler, son yıllarda farklı alanlarda yaygın olarak kullanılmaktadır. E-burundaki önemli konulardan biri de farklı gazların farklı konsantrasyon değerlerinin tahmin edilmesidir. Gaz konsantrasyonlarının doğru bir şekilde tahmin edilmesi, hastalık tespiti gibi hassas konularda da çok önemli bir rol oynamaktadır. Bu çalışma, derin öğrenme (*Deep Learning, DL*) ağlarını kullanarak 4 adet metal oksit gaz sensörü tarafından tespit edilen etanol, metan, etilen ve karbon monoksit gazlarının konsantrasyon seviyelerinin ve değerlerinin sınıflandırma ve regresyon başarılarının artırılması amacıyla yapılmıştır. Gazların konsantrasyon seviyelerine göre sınıflandırma başarılarının karşılaştırılmasında ve belirli bir aralıktaki konsantrasyon değerlerinin tahmin başarılarının karşılaştırılmasında farklı yöntemler kullanılmıştır. Bu işlemlerin gerçekleştirilmesi için gaz verilerine ön işleme ve farklı öznitelik çıkarımı adımları uygulanmıştır. Bu çalışmanın odak noktası, öznitelik çıkarımı yapılmasında yeni yöntemler geliştirerek sınıflandırma ve regresyondan elde edilen başarının artırılmasıdır. Bu amaçla, iki yeni metodoloji önerilmiştir. Geliştirilen yöntemlerden birinde, derin öğrenme ağlarından biri olan Uzun Kısa-Sürelili Bellek (*Long Short-Term Memory, LSTM*) ağlarının tam bağlantılı katmanından öznitelik çıkarımı yapılmış, çıkarılan öznitelikler sınıflandırma ve regresyonda kullanılmıştır. Önerilen diğer metodolojide ise LSTM ağının tam bağlantılı katmanından elde edilen veriler Zamansal Evrişimli Ağ (*Temporal Convolutional Network, TCN*) modeline giriş olarak uygulanmıştır ve bu TCN'nin tam bağlantılı katmanından elde edilen özniteliklerde sınıflandırma ve regresyon çalışmalarında kullanılmıştır (LSTMFCL-TCNFCL). Önerilen her iki yöntemin sonuçları geleneksel yöntemlere göre karşılaştırıldığında hem sınıflandırma hem de tahmin sonuçlarında iyileşme olduğu,

başarının arttığı ve ortalama karesel hataların da önemli ölçüde azaldığı görülmektedir. Ayrıca, ön işleme aşamasında sinyal düzeltme uygulandığı zaman sonuçlarda dikkate değer bir şekilde artış olduğu da görülmektedir. Hem sinyal düzeltmenin uygulanması hem de geliştirilen yöntemlerle sonuçlarda iki taraflı bir iyileşme olması sağlanmıştır. Sınıflandırmada Destek Vektör Makinesi (*Support Vector Machines, SVM*) algoritması 94,7% ile en yüksek doğruluk oranını verirken, regresyonda ise en düşük ortalama karesel hatalar Gauss Süreci Regresyonu (*Gaussian Process Regression, GPR*) ile elde edilmiştir.

ANAHTAR KELİMELER: Elektronik Burun, Derin Öğrenme, Uzun Kısa-Süreli Bellek Ağları, Zamansal Evrişimli Ağlar, Öznitelik Çıkarımı, Regresyon Yöntemleri, Sınıflandırma Yöntemleri



ABSTRACT

Hande BAKİLER

CLASSIFICATION OF GASES WITH DEEP NETWORK-BASED FEATURES AND REGRESSION ANALYSIS OF CONCENTRATION VALUES

Başkent University Institute of Science and Engineering

Department of Electrical and Electronics Engineering

2022

Electronic nose (e-nose) is a device based on electronic sensing technology that determines, identifies and classifies various properties by making precise measurements on volatile components emitted from biological materials with a chemical sensor array. These systems, which work by imitating the human olfactory mechanism, have been widely used in different fields in recent years. One of the important issues in e-nose is the estimation of different concentration values of different gases. Accurate estimation of gas concentrations plays a crucial role in sensitive issues such as disease detection. This study was carried out to increase the classification and regression success of the concentration levels and values of ethanol, methane, ethylene and carbon monoxide gases detected by 4 metal oxide gas sensors using deep learning networks. Different methods was used to compare the classification successes of gases according to their concentration levels and to compare the estimation successes of concentration values in a certain range. In order to perform these operations, preprocessing and different feature extraction steps were applied to the gas data. The focus of this study is to increase the success of the classification and regression by developing new methods for feature extraction. For this purpose, two new methodologies have been proposed. In one of the developed methods, feature extraction was made from the fully connected layer of Long Short-Term Memory (LSTM) networks, which is one of the deep learning networks, and the extracted features were used in the classification and regression. In the other proposed methodology, the data obtained from the fully connected layer of the LSTM network was applied as an input to the Temporal Convolutional Network (TCN), and the features obtained from the fully connected layer of this TCN were used in classification and regression studies (LSTMFCFCL-TCNFCFCL). When the results of both proposed methods are compared with the traditional methods, it is seen that there is an improvement in both classification and estimation results, the success is increased and the mean squared errors are significantly reduced. In addition, it is seen that there is a remarkable increase in the

results when signal correction is applied in the preprocessing stage. Both the application of signal correction and the developed methods have provided a bilateral improvement in the results. While the Support Vector Machine algorithm gave the highest accuracy rate with 94,7% in the classification, the lowest mean square errors in regression were obtained with the Gaussian Process Regression.

KEYWORDS: Electronic Nose, Deep Learning, Long Short-Term Memory Networks, Temporal Convolutional Networks, Feature Extraction, Regression Methods, Classification Methods.



İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iv
İÇİNDEKİLER.....	vi
TABLolar LİSTESİ	viii
ŞEKİLLER LİSTESİ	x
SİMGELER VE KISALTMALAR LİSTESİ	xii
1. GİRİŞ.....	1
2. ELEKTRONİK BURUN SİSTEMLERİ.....	6
2.1. Biyolojik Burun ve Elektronik Burun Sistemlerinin Karşılaştırması	7
2.2. Elektronik Burun Sistemlerinin Çalışma Prensibi	10
2.2.1. Örnek taşıma birimi.....	11
2.2.2. Sensör birimi.....	13
2.2.3. Örüntü tanıma birimi	23
3. METODLAR.....	24
3.1. Ön İşleme	24
3.2. Sinyal Düzeltme.....	25
3.3. Öznitelik Çıkarımı	26
3.4. Sınıflandırma.....	27
3.4.1. Karar ağacı	27
3.4.2. Doğrusal ve karesel ayırma analizi.....	29
3.4.3. Naïve Bayes	31
3.4.4. Destek vektör makineleri (Support Vector Machines, SVM)	32
3.4.5. K-en yakın komşu algoritması (K-Nearest Neighbours, KNN)	35
3.4.6. Kolektif öğrenme (Ensemble learning)	37
3.4.6.1. Torbalama (Bootstrap Aggregation, Bagging) yöntemi.....	37
3.4.6.2. Yükseltme (Boosting) yöntemi.....	38
3.4.6.3. Rastgele Alt Uzay (Random Subspace)	39
3.5. Regresyon	40
3.5.1. Doğrusal Destek Vektör Regresyonu (Support Vector Regression, SVR)..	41
3.5.2. Karar Ağacı Regresyonu (Decision Tree regression).....	42
3.5.3. Kolektif Öğrenme Regresyonu (Ensemble Learning Regression)	43

3.5.4. Gauss Süreci Regresyonu (Gaussian Process Regression)	45
3.5.5. Doğrusal Regresyon (Linear Regression)	46
4. DERİN ÖĞRENME AĞLARI	48
4.1 Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNNs)	49
4.2 Uzun Kısa-Sürelili Bellek (Long Short-Term Memory, LSTM) Ağları	52
4.3 Evrişimli Sinir Ağları (Convolutional Neural Networks, CNNs)	56
4.3.1 Zamansal Evrişimli Ağlar (Temporal Convolutional Neural Networks, TCNs)	63
5. TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR	66
5.1 Kullanılan Veri Tabanı	66
5.2 Ön İşleme Aşaması	68
5.3 Ham Verilerin İşlenmesi	71
5.4 Sensör Yanıtlarının Maksimum Değerlerine Göre Öznitelik Çıkarımı	71
5.5 LSTM Ağlarının Tam Bağlantılı Katmanından Öznitelik Çıkarımı	72
5.6 TCN Mimarısının Tam Bağlantılı Katmanından Öznitelik Çıkarımı	74
6. TARTIŞMA VE YORUM	79
7. SONUÇ	103
KAYNAKLAR	105

TABLolar LİSTESİ

Tablo 2.1. Çeşitli Hastalıklarda İnsan Nefesindeki Oranı Değişen Uçucu Bileşikler [42]. ..	7
Tablo 2.2. Elektronik burun ile insan burnunun karşılaştırılması [11].....	10
Tablo 2.3. E-burun uygulamalarında kullanılan sensörler [37, 55].....	22
Tablo 5.1. MOX sensör tipleri ve sensör tipine göre tespit edilen VOC türleri.....	66
Tablo 5.2. Her bir VOC için sunulan konsantrasyon seviyelerine göre sınıflandırma grupları ve açıklamaları.	67
Tablo 6.1. Sinyal düzeltme uygulanmadığı zaman ham veriler kullanılarak gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.....	80
Tablo 6.2. Sinyal düzeltme uygulandığı zaman ham veriler kullanılarak gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.	81
Tablo 6.3. Sinyal düzeltme uygulanmadığı zaman öznelik çıkarımında maksimum değerler kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.....	83
Tablo 6.4. Sinyal düzeltme uygulandığı zaman öznelik çıkarımında maksimum değerler kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.	84
Tablo 6.5. Sinyal düzeltme uygulanmadığı zaman öznelik çıkarımında LSTM ağıının tam bağlantılı katmanı kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.....	85
Tablo 6.6. Sinyal düzeltme uygulandığı zaman öznelik çıkarımında LSTM ağıının tam bağlantılı katmanı kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.....	86
Tablo 6.7. Sinyal düzeltme uygulanmadığı zaman öznelik çıkarımında LSTMFCL-TCNFCL modeli kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.....	88
Tablo 6.8. Sinyal düzeltme uygulandığı zaman öznelik çıkarımında LSTMFCL-TCNFCL modeli kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.....	89
Tablo 6.9. Sinyal düzeltme uygulanmadığı zaman önerilen yöntem ile geleneksel yöntemlerin elde edilen başarı oranlarının karşılaştırılması	90
Tablo 6.10. Sinyal düzeltme uygulandığı zaman önerilen yöntem ile geleneksel yöntemlerin elde edilen başarı oranlarının karşılaştırılması.....	91
Tablo 6.11. Karbon monoksit için sinyal düzeltme uygulanmadığı zaman elde edilen regresyon değerleri.	93

Tablo 6.12. Karbon monoksit için sinyal düzeltme uygulandığı zaman elde edilen regresyon değerleri.	94
Tablo 6.13. Etanol için sinyal düzeltme uygulanmadığı zaman elde edilen regresyon değerleri.	95
Tablo 6.14. Etanol için sinyal düzeltme uygulandığı zaman elde edilen regresyon değerleri.	96
Tablo 6.15. Etilen için sinyal düzeltme uygulanmadığı zaman elde edilen regresyon değerleri.	97
Tablo 6.16. Etilen için sinyal düzeltme uygulandığı zaman elde edilen regresyon değerleri.	98
Tablo 6.17. Metan için sinyal düzeltme uygulanmadığı zaman elde edilen regresyon değerleri.	99
Tablo 6.18. Metan için sinyal düzeltme uygulandığı zaman elde edilen regresyon değerleri.	100
Tablo 6.19. Karbon monoksit, etanol, etilen ve metan gazları için elde edilen en iyi regresyon değerleri.	101

ŞEKİLLER LİSTESİ

Şekil 2.1. İnsan koku alma sistemi [32].....	8
Şekil 2.2. E-burun ve insan burnunun sistem blokları.....	9
Şekil 2.3. Tipik bir e-burun sisteminin şematik diyagramı [45].....	11
Şekil 2.4. MOS sensörünün şematik gösterimi [57].....	15
Şekil 2.5. Sensör Devresi.....	16
Şekil 2.6. MOSFET'in Yapısı [57].....	17
Şekil 2.7. CP sensörünün şematik gösterimi [54].....	18
Şekil 2.8. Optik sensör yapısı	19
Şekil 2.9. BAW ve SAW sensörlerinin şematik diyagramları [54].....	20
Şekil 2.10. QCM sensörünün a) önden görünüşü b) yandan görünüşü [60].	21
Şekil 3.1. Karar ağacı yapısı [63].	28
Şekil 3.2. Eşit sınıf örneklem büyüklüğü ile gösterimler: (a) iki sınıf için LDA, (b) iki sınıf için QDA, (c) iki sınıf için Gauss Naive Bayes, (d) iki sınıf için Bayes, (e) üç sınıf için LDA (f) üç sınıf için QDA, (g) üç sınıf için Gauss Naive Bayes ve (h) üç sınıf için Bayes [78].	31
Şekil 3.3. SVM yönteminde hiper düzlemin belirlenmesi (a) doğrusal olarak ayrılabilen veri örnekleri (b) doğrusal olarak ayrılamayan veri örnekleri [87].	33
Şekil 3.4. KNN ve SVM sınıflandırma yöntemlerinin karşılaştırılması [91].....	36
Şekil 3.5. Kolektif Öğrenme Yönteminin Genel Yapısı [94].	37
Şekil 3.6. Torbalama (<i>Bagging</i>) yönteminin yapısı [94].	38
Şekil 3.7. Yükseltme (<i>Boosting</i>) yönteminin yapısı [94].	39
Şekil 3.8. Doğrusal SVR'de regresyon hiper düzlemi ve marjı [106].....	42
Şekil 3.9. Torbalama algoritması [114]	44
Şekil 4.1. Yapay Sinir Ağı [129].	48
Şekil 4.2. Yapay bir nöronun şematik gösterimi [128].....	49
Şekil 4.3. Tekrarlayan sinir ağı şeması [136].	50
Şekil 4.4. Zaman adımları içerisinde tekrarlanan RNN modeli [136].	51

Şekil 4.5. RNN’de mevcut durumun girişi ile önceki durumun çıkışının birlikte kullanılması [136].	51
Şekil 4.6. LSTM birimi içerisindeki bileşenler [138].	54
Şekil 4.7. Klasik bir CNN modeli katmanları [155].	57
Şekil 4.8. Evrişim katmanında filtrenin uygulanışı [129].	58
Şekil 4.9. Aktivasyon Fonksiyonları [148].	60
Şekil 4.10. Havuzlama Yöntemleri [148].	61
Şekil 4.11. Düzleştirme İşlemi [159].	61
Şekil 4.12. Tam Bağlantılı Katman	63
Şekil 4.13. TCN Mimarisi	64
Şekil 4.14. TCN Bloğu	65
Şekil 5.1. Etilen için 4 MOX gaz sensörünün ham sinyalleri.	69
Şekil 5.2. Etilen için 4 MOS gaz sensörünün iletkenlik sinyalleri.	69
Şekil 5.3. Etilen için 4 MOS gaz sensörünün aynı referans noktasından başlayan iletkenlik (ön işlenmiş) sinyalleri.	70
Şekil 5.4. Etilen için 4 MOS gaz sensörünün sinyal düzeltmesi uygulandıktan sonra elde edilen iletkenlik sinyalleri	70
Şekil 5.5. Sınıflandırma için LSTM Ağ Mimarisi	72
Şekil 5.6. Regresyon için LSTM Ağ Mimarisi	73
Şekil 5.7. LSTM ve TCN'nin tam bağlantılı katman verilerini kullanan öznetelik çıkarma yöntemi için veri işlemenin akış şeması.	77
Şekil 5.8. LSTM ve TCN'deki ağ yapılarının işlemleri için akış şeması	78

SİMGELER VE KISALTMALAR LİSTESİ

Adam	Uyarlanabilir Moment Tahmini (<i>Adaptive Moment Estimation</i>)
ADBR	Uyumlu artırıcı regresyonda (<i>Adaboost Regression</i>)
AI	Yapay Zekâ (<i>Artificial Intelligence</i>)
ANN	Yapay Sinir Ağı (<i>Artificial Neural Network</i>)
ATP	Adenozin Trifosfat (<i>Adenosine Triphosphate</i>)
BAW	Toplu Akustik Dalga (<i>Bulk Acoustic Wave, BAW</i>)
CCD	Yük Bağlısımlı Cihaz (<i>Charge Coupled Device</i>)
CMOS	Bütünleyici Metal Oksit Yarı İletken (<i>Complementary Metal Oxide Semiconductor</i>)
CNN	Evrişimli Sinir Ağı (<i>Convolutional Neural Network</i>)
ConvLSTM	Evrişimli Uzun Kısa Süreli Bellek (<i>Convolutional Long Short-Term Memory</i>)
CP	İletken Polimer (<i>Conducting Polymer</i>)
CRBM	Sürekli Kısıtlı Boltzmann Makinesi (<i>Conditional Restricted Boltzmann Machine</i>)
ÇDÇT	Çok Değişkenli, Çok Terimli
DAE	Gürültü Giderici Özkodlayıcı Ağlar (<i>Denoising Autoencoders</i>)
DBN	Derin İnanç Ağları (<i>Deep Belief Networks</i>)
DCNN	Derin Evrişimli Sinir Ağı (<i>Deep Convolutional Neural Network</i>)
DL	Derin Öğrenme (<i>Deep Learning</i>)
EUR	Tahmini Nihai Geri Kazanımını (<i>Estimated Ultimate Recovery</i>)
FCL	Tam Bağlantılı Katman (Fully Connected Layer)
GH	Gaz Hidrat (<i>Gas Hydrate</i>)
GPR	Gauss Süreci Regresyonu (<i>Gaussian Process Regression</i>)
GRBR	Gradyan artırılmış regresyon (<i>Gradient Boosting Regression</i>)
KNN	k-En Yakın Komşu (<i>K-Nearest Neighbours</i>)
LDA	Doğrusal ayırma analizi (<i>Linear Discriminant Analysis</i>)
LSTM	Uzun Kısa Süreli Bellek (<i>Long Short-Term Memory</i>)
MAE	Ortalama Mutlak Hata (<i>Mean Absolute Error</i>)
MEMS	Mikro Elektro-Mekanik Sistem (<i>Micro Electro-Mechanical System</i>)
MLP	Çok Katmanlı Algılayıcı (<i>Multi-Layer Perceptron</i>)
MLSTM	Çok Görevli Öğrenme Uzun Kısa Süreli Bellek (<i>Multi-Task Learning Long Short-Term Memory</i>)
MOS	Metal Oksit Yarı İletken (<i>Metal Oxide Semiconductor</i>)
MOSFET	Metal Oksit Yarı İletken Alan Etkili Transistör (<i>Metal Oxide Semiconductor Field Effect Transistor</i>)
MRE	Ortalama Bağlı Hata (<i>Mean Relative Error</i>)
MTMC-NLSTM	Çoklu İç İç Uzun Kısa Süreli Bellek Ağları (<i>Multiple Nested Long Short Term Memory Networks</i>)
MVMN	Çok Değişkenli Çok Terimli (<i>Multivariate Multinomial</i>)
ng	Nanogram
pg	Pikogram
PNN	Olasılıksal Sinir Ağı (<i>Probabilistic Neural Network</i>)
ppb	Parts Per Billion
ppm	Parts Per Million
QCM	Kuvars Kristal Mikroterazi (<i>Quartz Crystal Microbalance</i>)
QDA	Karesel ayırma analizinde (<i>Quadratic Discriminant Analysis</i>)
RBM	Kısıtlı Boltzmann Makinesi (<i>Restricted Boltzmann Machine</i>)

ReLU	Doğrultulmuş Lineer Ünite (<i>Rectifier Linear Unit</i>)
RF	Rastgele Orman (<i>Random Forest</i>)
RFR	Rastgele orman regresyonunda (<i>Random Forest Regression</i>)
RMSprop	Karelerin Ortalamasının Karekökü Yayılımı (<i>Root Mean Square Propagation</i>)
RNN	Tekrarlayan Sinir Ağı (<i>Recurrent Neural Network</i>)
SAW	Yüzey Akustik Dalgası (<i>Surface Acoustic Wave</i>)
STCKR	Yığın regresyonda (<i>Stacking Regression</i>)
SVM	Destek Vektör Makinesi (<i>Support Vector Machine</i>)
SVR	Destek Vektör Regresyonu (<i>Support Vector Regression</i>)
TCN	Zamansal Evrişimli Ağ (<i>Temporal Convolutional Neural Network</i>)
VOC	Uçucu Organik Bileşik (<i>Volatile Organic Compound</i>)
XGBoost	Aşırı Eğitim Artırma (<i>Extreme Gradient Boosting</i>)
XRD	X-ışını kırınımı (<i>X-Ray Diffraction, XRD</i>)



1. GİRİŞ

İnsan burnu ile uçucu organik bileşiklerin (*Volatile Organic Compounds*’, *VOCs*) analizi fiziksel, zihinsel, sağlık ve diğer çevresel faktörlerden oldukça etkilenir. Ayrıca insan burnu karbon monoksit ve karbondioksit gibi bazı gazları ise hiç algılamaz, algıladığı gazlarda da bir süre sonra yorgunluk oluştuğu için ortamda halen var olan koku algılanamamaktadır. Bu nedenle ürünlerin koku kalitesini değerlendirmek, tanımlamak ve daha tutarlı sonuçlar elde etmek için elektronik burun (e-burun) kullanılmaktadır [1]. E-burun gıda endüstrisi, kimyasal tespit uygulamaları, bilimsel araştırma, araba endüstrisi, çevre denetimi, tarım, tıp, eczacılık, gaz karışımlarındaki bileşenlerin tespiti, askeri sanayi, uzay teknolojisi gibi birçok alanda farklı uygulamalar için oldukça kullanışlıdır [2]. Örneğin tıp alanında vücuttan salınan uçucu bileşikler, enfeksiyonlar, metabolik hastalıklar, kanser hastalıkları gibi hastalıklarla ilişkilidir [3]. VOC’ler farklı hastalık türlerinin göstergesi olabilir [4]. Bu nedenlerden dolayı e-burun, VOC’lere göre farklı hastalıkları tanıyabilmektedir [5-8].

E-burun sistemleri [9-11], bir dizi elektronik sensör ve hem basit hem de karmaşık kokuları ayırt edebilen uygun bir örüntü tanıma sistemi içeren, insan duyularının taklit edilebildiği sistemlerdir. Farklı gaz karışımlarını karakterize etmeye çalışır ve gerçek zamanlı olarak hassas ve seçici analizler sağlayabilmektedir.

Elektronik burundan elde edilen sinyali tahmin etmek veya sınıflandırmak için birkaç yöntem kullanılır. Örüntü tanıma problemlerinde son yıllarda en sık kullanılan yöntemlerden biri derin öğrenme yöntemleridir. Derin öğrenme, makine öğrenmesinin bir alt dalıdır. Derin öğrenme, insan beyninin algılama ve karar verme özelliğini taklit eden, her katmanda geriye yayılım algoritması kullanarak büyük veri kümelerindeki gizli ve ayırt edici özellikleri keşfeden bir makine öğrenmesi alanıdır. Geleneksel makine öğrenimi algoritmaları doğrusaldır. Ancak derin öğrenme yöntemlerinde uygulanan alanın karmaşıklığına göre değişen bir model vardır. Ortaya çıkan başarı oranı belirli bir düzeye ulaşana kadar derin öğrenme süreci tekrarlanır [12]. Literatür incelendiğinde gazların tanınması ve ayırt edilmesi konusunda farklı derin öğrenme yöntemlerinin kullanıldığı görülmektedir. E-burun teknolojisinde gaz sınıflandırması Derin Evrişimli Sinir Ağı (*Deep Convolutional Neural Network, DCNN*) kullanılarak yapılmış ve DCNN yönteminin Destek Vektör Makinesi (*Support Vector Machine, SVM*) ve Çok Katmanlı Algılayıcı (*Multi-Layer Perceptron, MLP*) yöntemlerine göre daha yüksek sınıflandırma doğruluğu sağlayabildiği gösterilmiştir [13]. LSTM tekrarlayan sinir ağına ve gaz sensörleri dizisine dayalı olarak hava kirliliği

gazlarının tanınması üzerine araştırma yapılmıştır. LSTM, Yapay Sinir Ağı (*Artificial Neural Network, ANN*), SVM ve Tekrarlayan Sinir Ağı (*Recurrent Neural Network, RNN*) karşılaştırması sonucunda LSTM ile daha yüksek doğruluk elde edilmiştir [14]. Eşzamanlı gaz tespiti ve konsantrasyon tahmini için çok görevli öğrenme uzun kısa süreli bellek (*Multi-Task Learning Long Short-Term Memory, MLSTM*) tekrarlayan ağ önerilmiş ve deneyler yapılmıştır. İki görev arasındaki sinerji ağ tarafından kullanılmıştır, böylece performanslar iyileştirilmiştir. Deneysel sonuçlar, modelin eş zamanlı gaz tespiti ve konsantrasyon tahmini için en iyi performansı sergilediğini göstermiştir. Ek olarak, önerilen MLSTM modeli, özellikle sensör verileri heterojen, karmaşık ve eksik veri noktalarına sahipse, sistem girişleri ve çıkışları arasındaki doğrusal olmayan ilişkiyi tanımlayabilmiştir [15]. Çok modlu yapay zekâ (*Artificial Intelligence, AI*) tabanlı füzyon teknikleri kullanılarak gazların güvenilir bir şekilde tanımlanması ve tespit edilmesi için yeni bir yaklaşım önerilmiştir. LSTM kullanılarak gaz sensörü verilerine göre 82%, CNN kullanılarak termal görüntü verilerine göre 93% test doğruluğu elde edilirken, birleştirilmiş model için 96% test doğruluğu elde edilmiştir. Elde edilen sonuçlara göre, birden fazla sensör ve yöntemin birleştirilmesi, tek bir sensörün sonucundan daha iyi performans gösterdiği belirtilmiştir [16]. Karbon monoksit (CO), metan (CH₄) ve bu gazların karışımlarının tanımlanması, elektronik burun ile CNN kullanılarak gerçekleştirilmiştir ve üç gaz kategorisinin test doğruluğu 98.67%'ye ulaşmıştır. Önerilen yaklaşım, MLP sinir ağları, Olasılıksal Sinir Ağı (*Probabilistic Neural Network, PNN*) ve SVM gibi yöntemlerle karşılaştırıldığında en yüksek doğruluk elde edilmiştir [17]. CNN ve RNN'nin birleşimine dayanan ve CRGNN olarak adlandırılan yeni bir hızlı gaz tanıma algoritması, 4 tip gaz içeren mevcut bir veri setine uygulanmıştır. Önerilen algoritmanın SVM, KNN, Rastgele Orman (*Random Forest, RF*) gibi yaygın olarak kullanılan algoritmalara göre tespit süresi ve doğruluk açısından üstünlük sağladığı gözlemlenmiştir [18]. Sürekli Kısıtlı Boltzmann Makinesi (*Conditional Restricted Boltzmann Machine, CRBM*) olarak adlandırılan olasılık modeline dayanarak, boyut küçültme ve kümeleme kullanılarak bir e-burun tarafından algılanan VOC'lerin üst üste gelmesi ve yanlış sınıflandırılmasının üstesinden gelinmiştir [19]. CNN, e-burunların örnekleme süresini kısaltmak için kullanılmış ve CNN ile 15 sn ile daha kısa örnekleme süresi ve 95,7% sınıflandırma doğruluğu elde edilirken, geleneksel yöntemlere göre 92,9% sınıflandırma doğruluğu elde edildiği gösterilmiştir [20]. Elektronik burun verileri ile kanda ve agar solüsyonlarında bakteri varlığını tespit etmek için derin öğrenme (Kısıtlı Boltzmann Makinesi (*Restricted Boltzmann Machine, RBM*)) tabanlı yöntemler kullanılmış ve çalışma sonucunda uygulanan derin öğrenme yöntemlerinin daha önce aynı veri setiyle denen-

manuel olarak seçilen strateji tabanlı yöntemlere göre daha iyi performans gösterdiği görülmüştür [21]. Gerçek zamanlı gaz sınıflandırmasında, beş farklı e-burun veri tabanı kullanılarak hızlı tespit yaklaşımını doğrulamak için bir SVM algoritması ve üç farklı derin öğrenme (*Deep Learning, DL*) modeli kullanılmıştır. Bu algoritmalarla kullanılacak 15 veri seti dahil olmak üzere 5 farklı e-burun veri tabanı ile bir dizi deney gerçekleştirilmiştir. Ölçümler hakkında tam bilgi gerektiren geleneksel bir yaklaşıma kıyasla 15 veri setinin 14'ünde daha iyi veya benzer şekilde doğru sonuçlar elde edilmiştir. Sonuçlara dayanarak, önerilen yaklaşımın e-burun tahminlerini yapmak için yanıt süresini azalttığı sonucuna varılmıştır. Gaz örneklerinin 60%'ından fazlasında, ölçüm verilerinin yalnızca ilk 30%'u veya daha azı kullanılarak güvenilir tahminler elde edilmiştir. Hızlı tespit yaklaşımı, farklı sınıflandırma yöntemleri kullanılarak güvenilir tahmin modelleri oluşturulmuştur [22]. Metan sızıntısının tespit edilmesinde, sızıntı boyutunun sınıflandırılması bir video sınıflandırma problemi olarak ele alınmıştır ve videoları sızıntı hacmine göre sınıflandırmak için derin öğrenme modelleri geliştirilmiştir. İlk olarak, çok çeşitli sızıntı boyutları ve görüntüleme mesafelerini kapsayan, farklı sızıntı ekipmanlarından metan sızıntılarının ilk metan sızıntısı video veri seti toplanmıştır. Daha sonra bu video veri setlerine 2B Evrişimsel Sinir Ağları (CNN) modeli, 3B CNN ve Evrişimsel Uzun Kısa Süreli Bellek (*Convolutional LSTM, ConvLSTM*) dahil olmak üzere üç derin öğrenme algoritması uygulanmıştır. 3D CNN'nin (VideoGasNet) çalışılan sınıflandırma yöntemleri arasında en sağlam mimari olduğu gösterilmiştir. İkili kaçak/kaçak olmayan tespit doğruluğu yaklaşık 100%'e ulaşabilmektedir. En yüksek küçük-orta-büyük sınıflandırması 78,2%'ye ulaşabilmektedir [23]. Çalışmada, X-ışını kırınımı (*X-Ray Diffraction, XRD*) örüntüleri kullanılarak Ulleung Havzası'ndaki gaz hidrat (*Gas Hydrate, GH*) tortularının mineral bileşimini analiz edebilen bir makine öğrenme modeli geliştirilmiştir. GH tortusu, 12 mineral içeren karmaşık bir bileşime sahiptir. Öncelikli olarak veri toplama ve ön işleme aşamaları gerçekleştirilmiş, ardından CNN, RNN, MLP ve RF gibi çeşitli makine/derin öğrenme algoritmaları uygulanmıştır. 2,56%'lık bir ortalama mutlak hata (*Mean Absolute Error, MAE*) ile en düşük tahmin sonucu RF algoritması ile elde edilmiştir ve diğer algoritmalar, 3%'ün altındaki MAE'lerle makul bir şekilde performans göstermiştir [24]. Başka bir çalışmada, kaya gazı kuyularının tahmini nihai geri kazanımını (*Estimated Ultimate Recovery, EUR*) değerlendirmek için derin ileri beslemeli sinir ağlarına dayalı bir model tasarlanmıştır. Yöntemin geçerliliğini test etmek için WY kaya gazı kuyusundaki 282 kuyudan alınan gerçek veriler analiz edilmiştir. Elde edilen sonuçlara göre yüksek doğrulukta EUR tahmininin gerçekleştiği görülmektedir [25]. Doğal gaz boru hattı sızıntılarını tespit etmek

için bir çalışma gerçekleştirilmiştir. Tek bir metal oksit yarı iletken (*Metal Oxide Semiconductor, MOS*) gaz sensörü barındıran bir algılama cihazı kullanılarak verilerin toplanmasını sağlayan bir veri üretim cihazı tasarlanmıştır. Makine/derin öğrenme modelleri kullanılarak metan, simüle edilmiş doğal gaz karışımlarından ayırt edilebilmiştir. Ayrıca, metan ve etanın rastgele ikili karışımlarında doğru gaz konsantrasyonu tahminleri elde edilebilmiştir. Bu çalışmada KNN, RF, SVM, MLP ve CNN makine/derin öğrenme modelleri kullanılmış ve karşılaştırılmıştır. Metan, etan ve ikili karışımlar için sınıflandırmada 98,75% oranına ulaşılırken, regresyonda 12%'lik ortalama bağıl hata (*Mean Relative Error, MRE*) elde edilmiştir. Ayrıca, saf metan örnekleri sırasıyla 86,7% ve 93,3% doğrulukla 1% ve 3% etan içeren simüle edilmiş doğal gaz karışımlarından ayırt edilmektedir ve maksimum 19,3% MRE ile hem metan hem de etan bileşenlerinin konsantrasyon tahminleri gerçekleştirilmiştir [26]. Patlayıcı maddeleri tanımlamak için ve mevcut zamanla ilgili veriler kısıtlandığında, altı sensörden oluşan bir MOX kimyasal sensör dizisinde (elektronik burun) kullanılacak makine/derin öğrenme sınıflandırma modeli geliştirilmiştir. Bu nedenle, TNT veya barut ile sabun veya diş macunu birleştirilerek veya bu maddelerin belirli miktarlarda ham örnekleri alınarak 140 örnek elde edilmiştir. Sınıflandırma problemi için makine öğrenmesi tekniklerindeki farklı seçenekler arasından KNN, SVM, RF, CNN ve LSTM olmak üzere 5 model değerlendirilmiştir. LeNet-CNN ve LeNet-LSTM modelleri, 5 dakikalık veri kullanıldığında 100% doğrulukla sonuçlanmıştır ve 180 s gibi kısa bir sürede ise en az 98% doğruluk sağlamıştır. Bununla birlikte, zamanla ilgili daha az veriyle, LSTM sınıflandırıcısı bu doğruluğu yalnızca 30 sn korumuştur [27]. Diğer bir makalede, gaz türbinlerindeki arıza tespiti ile ilgili bir çalışma yapılmıştır. Gaz türbinlerindeki arıza tespitinde, gaz yolu arızaları ile sensör arızaları aynı anda meydana geldiğinde arıza tespiti zorlaşmaktadır. Aşırı Eğim Artırma (*Extreme Gradient Boosting, XGBoost*) tarafından optimize edilen CNN'nin performansını iyileştirmek için yeni bir yöntem geliştirilmiştir. CNN'nin kısmi özellikleri değiştirilerek ve CNN'ye giriş olarak verilen sinyal dizisinin etkisi optimize edilerek uygulanan yöntem, veri değişikliğine karşı daha duyarlıdır ve arızayı diğer sinir ağlarına göre daha hızlı bir şekilde önceden tespit edebilmektedir. Optimizasyon sonrasında, CNN ile elde edilen doğruluk 95,52% olup diğer yöntemlerden daha yüksektir. Geleneksel CNN'de 91,10% doğruluk oranı elde edilirken, RNN'de 94,21% doğruluk oranı elde edilmektedir [28]. Hava kalitesi indeksi veri tahmini için çoklu iç içe uzun kısa süreli bellek ağları (*Multiple Nested Long Short Term Memory Networks, MTMC-NLSTM*) modeli oluşturulmuştur. Önerilen yöntemin performansı, MLP, destek vektör regresyon (*Support Vector Regression, SVR*) gibi geleneksel makine

öğrenmesi (*Machine Learning, ML*) modellerinin ve çeşitli derin öğrenme modellerinin performansıyla karşılaştırıldığında, önerilen yöntemin performansının karşılaştırılan tüm mevcut modellerden üstün olduğu görülmektedir [29]. 8 MOX gaz sensör dizisi kullanılarak oluşturulan veri tabanındaki 5 karışık gazın zaman serisi verilerinin sınıflandırılmasında ve karşılaştırılmasında evrişimsel sinir ağları kullanılmıştır. Çalışmada, VGG-16, VGG-19, ResNet18, ResNet34 ve ResNet50 evrişimsel sinir ağları kullanılmıştır. Evrişimsel sinir ağlarında parametre ayarlamaları da yapılarak 96,67% gaz tanıma oranı elde edilmiştir [30].

Bu tezin temel katkısı, LSTM ve TCN derin sinir ağlarını kullanarak uçucu bileşikler konsantrasyon seviyelerine ve değerlerine göre ayırt etmek için yeni bir öznitelik çıkarma algoritması önermek ve bununla birlikte uygulanan sınıflandırma ve regresyon yöntemlerinde en yüksek başarıları elde etmektir. Bu öznitelik çıkarma algoritması, e-burun sistemlerindeki gazların sınıflandırılması ve regresyonu için şimdiye kadar uygulanmamıştır. Önerilen algoritma ile sınıflandırma ve regresyonda diğer yöntemlere göre daha yüksek başarı sağlanmıştır. Ayrıca ön işleme aşamasında da sinyal düzeltme eklenerek etkisi incelenmiş ve sonuçlardaki iyileşmenin arttığı gözlemlenmiştir. E-burun sistemlerinde, VOC'leri ayırt etmek için bu çalışmada kullanılan derin öğrenme ağları ile oluşturulan yapıdaki öznitelik çıkarma algoritması şimdiye kadar literatürde uygulanmadığı tespit edilmiştir. Bu tez çalışmasında önerilen yöntem ile başarılı sonuçlar elde edilmiştir.

Bu çalışmanın geri kalanı şu şekilde yapılandırılmıştır: 2. bölümde, elektronik burun sistemleri ayrıntılı bir şekilde açıklanmıştır. 3. bölümde, ön işleme aşamasında kullanılan yöntemler, öznitelik çıkarımı, sinyal düzeltme, sınıflandırma ve regresyon algoritmaları hakkında bilgi verilmiştir. 4. bölümde, derin öğrenme ağları olan LSTM, CNN ve TCN mimarileri ayrıntılı olarak açıklanmıştır. 5. bölümde, çalışmada kullanılan veri seti, tez kapsamında yapılan çalışmalar, geliştirilen yöntemler hakkında bilgi verilmiştir. 6. bölümde, uygulanan bu yöntemlere göre elde edilen sonuçlar tartışılmış ve ilgili yorumlar yapılmıştır. 7. bölümde ise yapılan çalışmalar, elde edilen sonuçlarla ilgili genel bir bilgi verilerek tez sonuçlandırılmaktadır.

2. ELEKTRONİK BURUN SİSTEMLERİ

Elektronik burun [31-33], gaz moleküllerini tekrarlanabilir şekilde ayırt etmek, tanımlamak, sınıflandırmak ve yoğunluklarını ölçmek için bir dizi gaz sensöründen gelen yanıt modelini kullanan bir sistemdir. E-burun sistemleri, gaz algılayıcı sensörlerden ve veri işleyicilerden oluşan, koku alma duyusunu taklit eden cihazlardır. Bir kokuyu tanıma süreci, kokuların neden olduğu kimyasal reaksiyonlar aracılığıyla bir sinyal olarak elektriksel değişim oluşturan her bir sensörün tepkilerinin alınmasıyla başlar. Dizide yer alan bu sensörlerin sayı ve tip seçimi, süreçteki seçicilik derecesini büyük ölçüde belirlemektedir. Sensörlerden gelen sinyal örüntüsü, verilerin örüntü tanıma yazılımı tarafından işlendiği bir bilgisayar tarafından toplanır ve işlenir.

Elektronik burunlar günümüzde birçok disiplinde kullanılmaktadır. E-burun, kimya mühendisliği [34], yiyecek ve içecek üretimi [35], çevre izleme [36], patlayıcı tespiti [37], kozmetik üretimleri [37] ve araçlardan kaynaklanan kirletici gazların tespiti [38] gibi çeşitli uygulamalarda başarıyla kullanılmıştır. Elektronik burnun belki de en önemli başarılarından birinin tıbbi uygulamalar alanında [39-42], özellikle bazı hastalıkların erken teşhisinde ortaya çıktığı söylenebilir. Nefes testi, hastalık teşhisi için etkili bir yöntemdir. Kültürlerden patojenlerin tanımlanması ve nefes örneklerinden hastalık teşhisi için e-burun kullanılmaktadır. Gıda maddelerinin bozulmalarının izlenmesi, belirli bir ortamda bakteri gelişiminin izlenmesi ile yakından ilgilidir. Başka bir deyişle, bir e-burun, hastalıklardan ve bakteri hücrelerinden gelen karakteristik kokuları tanıyabilmektedir çünkü hücre metabolizması, adenosin trifosfat (*Adenosine Triphosphate, ATP*) ve ikincil metabolitler vermek üzere glikoz gibi organik bileşiklerin biyolojik oksidasyonudur. Bazı hastalıkların karakteristik kokularla ilişkili olduğu iyi bilinmektedir, bu nedenle elektronik burunlar tıbbi uygulamalar, hastalık teşhisleri açısından önemlidir. Tablo 2.1’de, çeşitli hastalıklarda insan nefesindeki oranı değişen uçucu bileşikler gösterilmektedir.

Tablo 2.1. Çeşitli Hastalıklarda İnsan Nefesindeki Oranı Değişen Uçucu Bileşikler [42].


Uçucu Bileşikler	Hastalıklar
Alkanlar (hekzan, metil pentan), benzen türevleri (o toluidine ve anilin)	Akciğer kanseri
Amonyak (Hastada 100- 500ppb)	Karaciğer fonksiyonları, siroz, karaciğer ensefalopatisi
Aseton (0,1-10 ppm), (0.26- 4,9ppm), (1- 5ppm)	Diyabet, ketozis
Asetilen	Akciğer fonksiyonları
Etan (3-100 ppb)	Yağ peroksidasyonu, oksidatif stres
Etanol	Diyabet hastalığı
Formaldehit (1-8 ppm)	Kanserli tümör
Hidrojen	Mide bağırsak hastalıkları, yorgunluk belirtisi
Hidrojen peroksit	Astımlı hastalar
İzopren (sağlıklı kişi 89±36ppb, hastada hemodiyaliz öncesi 138±63 ppb, hemodiyaliz sonrası 184±95ppb), hastada 40-400 ppb)	Kolesterol sentezleri, hemodiyaliz cevabı, akut miyokardiyal damar tıkanıklığı, böbrek yetmezliği
Sülfür Hekzaflorür	Akciğer fonksiyonları
Karbondisülfid	Kalp damarlarının kan pıhtısı ile tıkanması
Amonyum, mercaptanlar, alifatik asitler	Karaciğer, siroz
Metan (Hastada 1-8 ppm)	Sindirim fonksiyonları, kolik fermentasyon
Monometilamin, dimetilamin, trimetilamin, amonyak	Kronik böbrek yetmezliği
Nitrik oksit (sağlıklı kişi 5-20ppb, hastada 30-80ppb)	Astımlı hastalar
Pentan (Hastada 4-20ppb)	Yağ peroksidasyonu, oksidatif stres, kalp nakil reddi, bağışıklık cevabı, göğüs ve akciğer kanseri, bronşit, damar tıkanıklığı, şizofreni, romatizmal kireçlenme

2.1. Biyolojik Burun ve Elektronik Burun Sistemlerinin Karşılaştırması

Uçucu organik bileşenlerin akıllı sistemler tarafından tespiti, karmaşık bir araştırma konusudur ve başta sinyal işleme olmak üzere sensör çeşitleri, gelişmiş örüntü tanıma yöntemleri gibi birçok adımla ilgili kapsamlı bir analiz içermektedir. Bir elektronik burun, belirli gazlara maruz kaldığında iç direnç değeri yükselen veya düşen bir dizi gaz sensöründen oluşmaktadır [43]. Elektronik burun güvenilir ve tekrarlanabilir sonuçlar verir, düşük maliyete sahiptir, uzman kullanımı gerektirmez, hızlı performansa sahiptir ve taşınabilir boyuttadır. İnsan burnu her türlü VOC'ye karşı hassas değildir. Bu sistemler öncelikle kimya endüstrisinin bütan, metanol, toluen, etanol, etilen, propan, izopropil alkol,

hidrojen, amonyak ve kloroform gibi gazları algılaması için geliştirilmiştir. Bazıları zehirlidir ve bazılarının hiç kokusu yoktur. E-burun sistemleri, insan burnunun algılayamadığı karbon monoksit ve doğalgazı da algılayabilirler. Ayrıca, insanlar için tehlikeli olan VOC'ler için bir algılama sistemine sahip olmak da önemlidir. İnsan burnunda bir süre sonra yorgunluk durumu oluşmakta ve ortamdaki gazları tanıyamamaktadır. Kişi aynı yoğunluktaki kokuyu farklı nitelendirebilmektedir. Ayrıca nezle, grip gibi bazı üst solunum yolu rahatsızlıklarında insan burnu kokuları eski hassasiyetiyle alamamaktadır. Bunun dışında insan burnu, kişiye özgü farklı hassasiyet göstermektedir. Oysa elektronik burunlar aynı kokulara her zaman aynı sonuçları verirler yani objektiftirler. Hasta olmazlar. Yıllarca aynı işi görebilmekte ve insan burnunun algılayamadığı gazları kullandıkları gaz algılayıcı sensör dizisine bağlı olarak rahatlıkla algılayabilmektedirler [32, 44, 45].


Biyolojik burun ile karşılaştırma yapılmadan elektronik burun tartışılmaz. Biyolojik burun için; burun boşluğunda bulunan mukoza ve tüycükler (silya) koku moleküllerinin filtrelenmesi ve konsantrasyonunu sağlar. Koku molekülleri, akciğer tarafından sağlanan pasif basınç nedeniyle koku alma (olfaktör) epiteline getirilir. Olfaktör epiteli milyonlarca algılama hücresi içerir ve bu hücrelerin membranlarında olfaktör reseptörleri bulunur. Tek bir koku alma reseptörü genellikle birkaç koku maddesine yanıt verir ve her bir koku molekülü, birden fazla koku alma reseptörü ile etkileşime girebilir. Reseptörler, kimyasal sinyalleri elektronörografi sinyallerine dönüştürürler. Bu elektronörografik sinyallerin benzersiz örüntüsü, olfaktör korteksi sinir ağı tarafından yorumlanır. Şekil 2.1'de biyolojik burun koku alma sistemi gösterilmektedir [11, 46].



Şekil 2.1. İnsan koku alma sistemi [32].

Elektronik burun sistemi, koku alma reseptör hücrelerinin bir kimyasal sensör dizisi ile değiştirildiği yapay bir koku alma sistemidir. Sensörler, bir kokunun sensörün kendisiyle etkileşimine yanıt olarak zamana bağlı bir elektrik sinyali üretir. Koku soğancığı, sensör

kaymasını ve gürültüyü dengeleyen bir veri ön işleme birimi tarafından temsil edilir. Yapay koku almanın son aşaması, insan beynine karşılık gelen örüntü tanıma sistemidir. Şekil 2.2'nin üst paneli, biyolojik bir burnu ve önemli özelliklerini gösterirken, Şekil 2.2'nin alt paneli ise yapay elektronik burnu göstermektedir.



Şekil 2.2. E-burun ve insan burnunun sistem blokları

Elektronik burun, biyolojik burun gibi farklı gaz karışımlarını karakterize etmek için kullanılır. Bununla birlikte hem donanımda hem de yazılımda bazı temel farklılıklar vardır. Elektronik burun ve insan burnu arasındaki karşılaştırmaların detayları Tablo 2.2'de listelenmiştir.

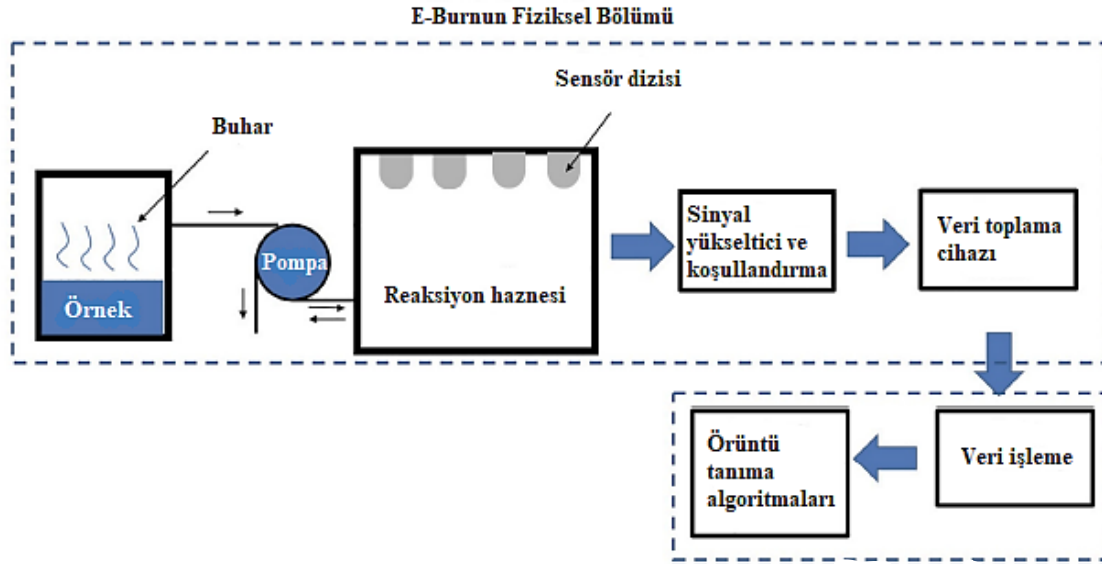
Tablo 2.2. Elektronik burun ile insan burnunun karşılaştırılması [11].

Biyolojik Burun	Elektronik Burun
Kokuyu epitel tabakasına getirmek için akciğerleri kullanır.	Kokuyu almak için bir pompa kullanır.
Filtre görevi görecektir mukus, zar ve tüycükler (silya) vardır.	Filtreleme sağlayan giriş örnekleme sistemi vardır.
İnsan burnu, benzersiz bir şekilde koku veren maddelerle etkileşime giren milyonlarca algılama hücresi içeren koku alma epitelini içerir.	Elektronik burun, bir grup koku molekülüyle farklı şekilde etkileşime giren çeşitli sensörlere sahiptir.
İnsan reseptörleri, kimyasal yanıtı, yorumlama için üst beyne ulaşmadan önce, benzersiz örüntüleri karmaşık bir ağ yoluyla nöronlar tarafından yayılan elektronik sinir uyarılarına dönüştürür.	Benzer şekilde elektronik burundaki kimyasal sensörler de örnekle reaksiyona girerek elektrik sinyalleri üretir. Bir bilgisayar, sinyallerin benzersiz örüntüsünü okur ve bunları örüntü sınıflandırma algoritmasıyla analiz eder.

2.2. Elektronik Burun Sistemlerinin Çalışma Prensipleri

Elektronik burun sistemlerindeki amaç, her kokunun bileşenlerinin karakteristik bir örüntüsünü bırakmasından kaynaklanmaktadır. E-burun sistemlerinin genel çalışma prensibi şu şekildedir: Uçucu bileşiklerin sensörün aktif malzemesinin yüzeyi ile etkileşime girmesiyle başlayan süreç, kimyasal reaksiyon bir elektrik sinyaline dönüştürüldüğünde gerçekleşen her bir sensörden gelen sinyal yanıtlarının bir araya getirilmesiyle başlar. Kimyasal sensörlerin çoğu, çeşitli analitik yöntemler için bir yanıt profilini temsil eder. Algılanması beklenen kokuların seçicilik derecesi ve türü, büyük ölçüde seçim yöntemine ve sensör sayısına bağlıdır. Gaz akışını kontrol etmek için gaz girişleri ve çıkışlarını içeren sensörleri monte etmek için hava geçirmez bir hazne kullanılır. Bu hazne genellikle sabit sıcaklık ve neme sahiptir, aksi halde gaz moleküllerinin adsorpsiyonunu etkileyecektir. Her sensörden gelen sinyaller bir analogdan dijital dönüştürücü (A/D) kullanılarak ölçülür ve işlenir, dijital sinyali okuyan ve çıktıyı görüntüleyen bir bilgisayar mikroişlemcisi vardır. Sinyal işlemekten sonra, verileri dönüştürmek için çoklu sensör yanıtının karmaşıklığını azaltmak için tasarlanmış çeşitli ön işleme teknikleri uygulanır. Daha sonra, örüntü tanıma,

gaz moleküllerini birbirinden ayırt etmek veya bilinen yanıtların bir koleksiyonuna dayalı bir sınıflandırma sağlamak üzere sistemi eğitmek için uygulanabilir. Kısaca elektronik burunlar, tek tek kimyasalların veya kimyasal karışımların analizini sağlayarak insanın koku alma duyusunu taklit edebilecek şekilde tasarlanır. Gazları ve kokuları analiz etmek ve karşılaştırmak için etkili bir yol sunarlar [47]. Şekil 2.3'te tipik bir e-burun sisteminin donanım ve yazılım birimlerinin çalışma prensibi şematik olarak gösterilmektedir.



Şekil 2.3. Tipik bir e-burun sisteminin şematik diyagramı [45].

Elektronik burun sistemi, farklı seçiciliğe sahip bir dizi kimyasal sensör, bir sinyal ön işleme ünitesi ve bir örüntü tanıma sisteminden oluşur. Uçucu organik bileşikler (VOC) ile bir sensör dizisi, tanıma sisteminde önceden kaydedilmiş örüntülerle karşılaştırılarak tanınabilecek karakteristik bir parmak izi oluşturur. Daha geniş anlamda, bir elektronik burun cihazı üç birimden oluşur [41, 44, 46, 48, 49]): örnek taşıma birimi, sensör birimi ve örüntü tanıma birimi.

2.2.1. Örnek taşıma birimi

Bu birim, analiz edilecek örnek kokuları ve uçucu bileşikleri sensörlerin bulunduğu kısma taşıma görevini yerine getirmektedir. Örnekler arasındaki nem, sıcaklık ve konsantrasyon gibi parametrelerin değişimini minimum seviyede tutmakla görevli kısımdır. Amacı sinyali zenginleştirmek, temizlemek ve geliştirmek olan bir ön işlem adımını içerir. Bu adım yavaş ve emek yoğun olma eğiliminde olsa da uygun bir örnekleme tekniği benimseyerek analizin kalitesini artırır. Örnek taşıma biriminin görevi, örneği toplamak, koşullandırmak ve sensör haznesine aktarmak ve ardından bir temizleme prosedürü

aracılığıyla sensörü eski haline getirmektir. Bu biriminin tasarımı, sensör tepkilerini etkileyebilecek sıcaklık, nem vb. tüm faktörleri sağlamalıdır. Bu faktörler gerekli parametreler altında tutulur, böylece örnekte sadece koku bileşimi korunur. Bu tip örnekleme birimi tasarımı, iyi stabilite, tekrarlanabilirlik, hızlı sensör yanıtları ve yüksek genlikli sinyaller sağlar. Örnekleme, veri toplamanın ilk temel adımı olduğundan ve dolayısıyla yürütülmesi, birbirini takip eden tüm adımları etkilediğinden, bu faktörler oldukça önemlidir. Örneklerden çıkarılan uçucu bileşiklerin elektronik burun algılama sistemine sokulmasına yönelik mevcut ana teknikler bundan sonra açıklanmaktadır.

Dağıtım sistemi, gaz örneklerini sensör haznesine getirir. Dağıtım manuel veya otomatik olabilir. Manuel dağıtım yönteminde, örneği doğrudan sensör bölmesine enjekte etmek için bir şırınga kullanılabilir ve homojen bir karışımı garanti etmek için içerideki hava küçük bir fan ile karıştırılabilir. Ancak, bu dağıtım yaklaşımı zaman alıcıdır ve çok kesin olmayabilir. Otomatik dağıtım sisteminde, tekrarlanabilirliği garanti etmek ve sensörün yanıt kaymasını en aza indirmek için akış hacmi, hız kontrolü, nem ve sıcaklık düzenlemesi olan otomatik bir pompa kullanılabilir. Sensörün önceki örneklerle zehirlenmesini azaltmak için her örneklemeden önce ve sonra temiz havanın pompalandığı bir temizleme döngüsü kullanılır [44].

E-burunda, ölçüm örneğini işlemek için iki ana yöntem vardır: Tepe boşluğu örnekleme ve çevrimiçi ölçüm. Bu iki stratejideki farklılıklar temel olarak farklı bir bakış açısından kaynaklanmaktadır. Tepe boşluğu örnekleme durumunda, "örnekleme eylemi", örneği E-burna iletmektir, çevrim içi ölçüm durumunda ise "örnekleme eylemi" için E-burun örnek ortamına getirilmektedir.

a) Tepe boşluğu örnekleme: Tepe boşluğu örnekleme yönteminde [41, 50, 51], tepe boşluğu, bileşimini değiştirmeden mümkün olan en yüksek verimlilikle örneklenmelidir. Bir örneğin Tepe Boşluğu (HS) uçucu organik bileşikler içerir. Kimyasal gaz sensörleri tarafından tepe boşluğunun ölçümü, örneğin doğası ve bileşimi hakkında bilgi verir. Bu tepe boşluğu veya gaz hacmi, daha fazla analiz için örnek taşıma birimi tarafından sensör haznesine getirilir.

Bu yöntemin doğru ve etkili bir şekilde uygulanması, ayrılma katsayısı (k) ve faz oranının (β) dikkatli bir şekilde izlenmesi ile elde edilir. Ayrılma katsayısı k , (2.1)'de verilmektedir.

$$k = \frac{C_i(s)}{C_i(g)} \quad (2.1)$$

Burada, $C_i(s)$ sıvı/katı örnek fazıdır, $C_i(g)$ ise analitin gaz fazındaki konsantrasyonlarıdır. Düşük k değerlerine sahip bileşikler, gaz fazına daha kolay ayrılma eğiliminde olacak ve nispeten yüksek tepkilere ve düşük tespit limitlerine sahip olacaktır.

Ayrılma katsayısıyla eşleşmesi için bir diğer önemli parametre, (2.2)'de verildiği gibi örnek şişesindeki örnek hacmine ($v(s)$) kıyasla tepe boşluğunun ($v(g)$) nispi hacmi olarak tanımlanan faz oranıdır (β). k ve β için daha düşük değerler; yani, daha büyük örnek boyutu, uçucu bileşikler için daha yüksek tepkiler verecektir.

$$\beta = \frac{v(g)}{v(s)} \quad (2.2)$$

b) Doğrudan maruz kalma: Doğrudan maruz kalma yönteminde [52, 53], belirli bir uygulama doğrudan izlenir. Herhangi bir hazne olmadan kokunun iletilmesine “Doğrudan Maruz Kalma” denir. Bu yöntem, doğrudan hava koşullarına maruz kalan çevresel E-burun uygulamaları için kullanışlıdır. Aslında bu yöntemde koku işleme ve dağıtım sistemi herhangi bir örnek akış ünitesine ihtiyaç duymaz. Bunun yerine, statik sistemlerde “Doğrudan Maruz Kalma” hazneleri kullanılır. Sensör dizisinin bir hazne içine monte edildiği durumlarda, koku işleme ve dağıtım sistemi dinamiktir ve bir örnek akış ünitesi kullanır. Haznenin girişinde ve çıkışında iki adet valf kullanılarak hedef gaz için kısa süreli kapalı bir döngü oluşturulabilir. Difüzyon yöntemi, permeasyon (sızdırma) yöntemi, bubbler (baloncuk tipli) yöntemi ve örnekleme torbaları gibi yöntemler örnek akış sisteminin farklı türleridir.

2.2.2. Sensör birimi

Elektronik burun cihazlarının en önemli elemanları kimyasal gaz sensörleridir. Sensör biriminde [10], sensörler tarafından ortamdan toplanan sinyaller elektronik sistemler aracılığıyla ikili kodlara dönüştürülerek analize hazır hale getirilir. Elektrokimyasal prensipte çalışan gaz sensörleri, VOC'lere maruz kalmaları sonucunda oluşan kimyasal bilgileri elektriksel bilgilere dönüştürmek için kullanılır. Kullanılan sensörlerin her biri farklı kimyasal uçucu bileşiklere karşı farklı hassasiyete sahip olduğundan; sensörlerin voltaj, iletkenlik, kapasite, içlerinden geçen akım gibi özellikleri de farklı olacak ve farklı

elektiriksel tepkiler üreteceklerdir. E-burnun yanıtı, dizideki tüm sensörlerin yanıtlarının uygun şekilde işlenmesiyle elde edilir.

Daha iyi algılama için, tek bir sensör yerine sensör dizileri tercih edilir. E-burnun çalışma hassasiyeti, kullanılan sensörün algılama özelliğine ve sinyal işleme biriminin çözünürlüğüne bağlıdır. Sensörler ne kadar iyi algılasa, sonuç o kadar doğru olur. Kullanılacak sensör, kullanım amacı ve konumu dikkate alınarak çok iyi seçilmelidir. Sensörlerin hedef gaza duyarlılığı, sensörün yapıldığı malzemeye ve sensörün nasıl çalıştığına bağlıdır. İdeal sensörler bazı kriterleri karşılayabilmelidir. Bunlar, sıcaklık ve neme karşı düşük hassasiyet, kimyasal bileşiklere (insan burnu gibi) karşı yüksek hassasiyet, yüksek stabilite, dayanıklılık, kısa reaksiyon süresi, kolay kalibrasyon, kolay işlenebilir veri çıkışı, yüksek güvenilirlik ve yüksek tekrarlanabilirliktir [54].

Elektronik burunda [55], dizideki her bir sensör farklı hassasiyete sahiptir. Örneğin, 1 No'lu gaz örneği, bir sensörde yüksek tepki ve diğerlerinde daha düşük tepkiler üretebilirken, 2 No'lu gaz örneği, 1 No'lu gaz örneğini “alan” sensör dışındaki sensörler için yüksek okumalar üretebilir. Önemli olan, sensörler arasındaki yanıt örüntüsünün farklı gaz örnekleri için farklı olmasıdır. Bu ayırt edilebilirlik, sistemin sensör yanıtlarının örüntüsünden bilinmeyen bir kokuyu/gaz örneğini tanımlamasına olanak tanır. Dizideki her sensör, test edilen VOC spektrumuna benzersiz bir yanıt profiline sahiptir. Dizideki tüm sensörlerdeki yanıt modeli, gaz örneğini tanımlamak ve/veya karakterize etmek için kullanılır.

Sensörlerden alınan bir elektrik sinyali, bilgisayarda işlenmek için yeterli olmadığından sinyal koşullandırması yapılmalıdır [56]. Ardından, bilgisayarda uygulanan örüntü tanıma biriminde işlenmek üzere sinyale bir analogdan dijitale dönüştürme uygulanır [10, 32].


Tez çalışmasında kullanılan veri tabanı elde edilirken Figaro sensörler kullanılmıştır. Figaro sensörlerinin en büyük avantajı, ticari olarak düşük bir fiyata temin edilebilmeleridir. Figaro sensörleri yanıcı ve kokusuz zehirli gaz dedektörleri gibi endüstriyel uygulamalarda da kullanılmaktadır. Bu sensörlerin birçoğunun doğada bulunan organik bileşiklerden ve solventlerden, gıdalardan, alkollerden ve bazı zehirli gazlardan kaynaklanan uçucu buharlara da duyarlı olduğu bulunmuştur. Figaro sensörleri ayrıca sigara dumanı, benzin ve mazot egzozu gibi doğal olmayan kokuları da algılayabilir [44].

a) Metal Oksit Yarı İletken (Metal Oxide Semiconductor, MOS) Gaz Sensörü:

Yarı iletken metal oksitlerin kimyasal duyarlılığına dayanan gaz algılama teknolojisi, diğer


gaz sensörleri sınıflarından ziyade koku ölçümünde diziler oluşturmak için yaygın olarak kullanılmaktadır. Elektronik burunlarla ilgili ilk araştırmaların çoğunda MOS [47, 57, 58], sensör dizilerini oluşturmak için en baskın teknoloji olmuştur. MOS, çalışma prensibi açısından MOSFET'e benzer ve yarı iletken, en tipik olarak kalay dioksit (SnO_2) ile kaplanmış bir ısıtma elemanından oluşur. Algılayıcı malzeme daha sonra az miktarda katalitik metal katkı maddesi örn. paladyum veya platin ile katkılanır. Sensörün katkılanması, sinterlenmiş malzemenin parçacık boyutunu değiştirerek çalışma koşullarının değişmesine neden olur, buna göre sensörün farklı maddelere olan seçiciliği üzerinde de bir etki gösterir.

MOS yüzeyindeki redoks reaksiyonlarında yer alan VOC'lere veya MOS çalışma sıcaklıklarında oksitleyici gibi davranan NO gibi gazlara maruz kalındığında dirençte bir değişiklik olur. İşlem, oksitleme ve indirgeme aşamaları ile açıklanabilir. Oksitleme aşamasında, havadan O_2 adsorbe edilir, yarı iletkenin iletim bandından serbest elektronları yakalar ve sensörün direncini artırır. Adsorbe edilen oksijen, metal oksit içindeki parçacık (grain) sınırları arasında potansiyel bir bariyer oluşturur. İndirgeme aşamasında, adsorbe edilen oksijen VOC ile reaksiyona girer, bu da oksijenin yüzey yoğunluğunun azalmasına, elektron yakalama etkisinin azalmasına ve böylece elektronların iletim bandına geri dönmesine izin verir. Dirençteki değişiklik, metal oksit parçacık boyutunun yanı sıra, algılama yüzeyinde adsorbe edilmiş oksijen ile reaksiyona giren VOC'ye bağlıdır. Seçicilik, katalizör veya sensör için çalışma koşulları değiştirilerek elde edilebilir. MOS, sensör yüzeyinde hızlı ve geri dönüşümlü reaksiyonlara izin verir ve VOC'ler ile reaksiyonu önleyecek bir kimyasal olarak emilmiş su tabakasının oluşmasını önler. Alkoller gibi yanıcı maddelere karşı hassastırlar, ancak nitrojen ve kükürt bazlı kokuları tespit etmede daha az hassastırlar. Şekil 2.4'te MOS sensörünün yapısı şematik olarak gösterilmektedir.



Şekil 2.4. MOS sensörünün şematik gösterimi [57].

Sensörlerin iki voltaj girişi vardır: Isıtıcı voltajı (V_H) ve devre voltajı (V_C). Isıtıcı voltajı (V_H), sensörün gazla kimyasal tepkimeye girebilmesi için, sensörü uygun olan belirli bir sıcaklıkta tutmak amacıyla devreye uygulanır. Sensörle seri olarak bağlanan yük direnci (R_L) üzerinden voltaj (V_{out}) ölçümüne izin vermek için devre voltajı (V_C) uygulanır. Sensörün polaritesi olduğundan devre voltajı için DC voltajı gereklidir. Sensörün elektrik gereksinimlerini karşılamak için V_C ve V_H için ortak bir güç kaynağı devresi kullanılabilir. Yük direncinin (R_L) değeri, yarı iletken güç tüketimini (P_S) 15mW sınırının altında tutarak eşik değerini optimize edecek şekilde seçilmelidir. Güç tüketimi (P_S), gaza maruz kalması durumunda R_S değeri R_L 'ye eşit olduğunda en yüksek olacaktır. Sensör devresi Şekil 2.5'te gösterilmektedir.



Şekil 2.5. Sensör Devresi


Güç tüketiminin değeri (P_S), aşağıdaki formül kullanılarak hesaplanabilir:

$$P_S = \frac{(V_C - V_{out})^2}{R_S} R_L \quad (2.3)$$

Sensör direnci (R_S) ise, aşağıdaki formül kullanılarak ölçülen bir V_{out} değeri ile hesaplanır:

$$R_S = \frac{V_C - V_{RL}}{V_{RL}} R_L \quad (2.4)$$


b) Metal Oksit Yarı İletken Alan Etkili Transistör (Metal Oksit Yarı İletken Alan Etkili Transistör, MOSFET): MOSFET'in çalışma prensibi, uçucu organik bileşiklerin MOSFET'in kapı kısmındaki metal ile reaksiyon oluşturmaya ve bu reaksiyonun sensör çıkışında gerilim değişimi meydana getirmesine dayanmaktadır. MOSFET'in metal kapı (gate) ucuna uygulanan potansiyel akımı belirler. Yarı iletken-yalıtkan sınırında elektrik akımının kaynaktan (source) savağa (drain) akmasına izin veren bir kanal oluşturur. Transistörün savak akımı, yarı iletkenin yüzey potansiyeli tarafından kontrol edilir. Metal kapı veya yalıtkan özelliklerinde bir değişikliğe neden olan herhangi bir gaz reaksiyonu, MOSFET sensörlerinin elektriksel özelliklerinde ve dolayısıyla savak akımında bir değişiklik sonulanacaktır; ancak MOSFET'ler için sensör tepkisi genellikle, savak akımını önceden seçilmiş bir değerde sabit tutmak için gereken kapı gerilimindeki değişiklik ile ölçölür. MOSFET'lerin çalışması için farklı sıcaklıklarda çalışmak, kapı metalinin değıştirilmesi ve metal kapının kalınlığı ve gözenekliliğinin önemli olduėu gösterilmiştir. Gaz algılama için hem n hem de p kanallı MOSFET'ler kullanılmaktadır. Şekil 2.6'da MOSFET'in yapısı şematik olarak gösterilmektedir [57].



Şekil 2.6. MOSFET'in Yapısı [57]

c) İletken Polimer (Conducting Polymer, CP) sensörler: İletken polimerler [41, 47], farklı tersinir fiziksel kimyasal özellikler ve uçucu bileşik gruplarına karşı yüksek hassasiyet sağladıkları için elektronik burunlarda sensör elemanları olarak yaygın olarak kullanılmaktadır. CP'ler, organik bileşiklere yanıt olarak iletkenliklerini ayarlama yeteneklerine sahiptirler. İletken polimerler, çok çeşitli organik buharlara duyarlı oldukları için metal oksit sensöründen farklıdır. Ayrıca cihazlar küçüktür ve düşük güç tüketimi ile oda sıcaklığında çalışabilir. Bu sensörlerde, polimerler ve uçucu bileşikler arasındaki etkileşim, sensör yüzeyindeki iletken polimerlerin direncinde değişikliğe yol açar. Farklı polimerler, farklı fizyokimyasal özelliklere sahip çeşitli uçucu bileşiklere tepki verir ve

CP'lerin özellikleri büyük ölçüde katkı düzeyine, katkı maddesinin iyon boyutuna, protonasyon düzeyine ve su içeriğine bağlıdır. Yüksek sıcaklıkta çalışan MOS ile karşılaştırıldığında, CP sensörleri ortam sıcaklığı koşullarında VOC'lere hızlı bir şekilde yanıt verebilir. Bununla birlikte, CP'ler, polimerin zamanla oksidasyonu nedeniyle nemden ve sensör kaymasından kolayca etkilenmektedirler. CP sensörünün yapısı Şekil 2.7'de gösterilmektedir.




Şekil 2.7. CP sensörünün şematik gösterimi [54].

d) Optik sensörler: Optik sensörler [37, 41, 59], hassas bir şekilde ölçülebilen tepkileri nedeniyle birçok uygulamada gaz sensörleri olarak yaygın şekilde kullanılmaktadır. Bir optik sensör, bir ışık kaynağı, bir algılama platformu, ışık dalga kılavuzları ve bir ışık detektöründen oluşur. Optik sensörler uçuş halindeki parçacıkları ölçer. Algılama mekanizması, ışığın ve algılama katmanının hedef gaz moleküllerine maruz bırakılmadan önceki ve sonraki etkileşimlerine dayanır. Işık yoğunluğunun değişmesi veya ışığın dalga boyunun kayması, ilgilenilen analitlerin varlığında meydana gelebilecek temel değişikliklerdir. Bu sensörlerin çalışma prensibi şöyledir: Bir sensör ve bir ışık hüzmesi birbirine belirli bir açıda yerleştirilmiştir. Parçacık ışığın önünden geçtiğinde, ışık sensöre geri yansır. Sensör, yansıyan bir ışık algıladığında bir sinyal üretir. Sensörün etrafındaki hava akışı sabitse, bu sinyalin uzunluğu parçacığın boyutunu tespit etmek için kullanılabilir.

Optik sensör sistemleri, elektrik direncindeki değişikliklere dayalı transdüksiyon mekanizmalarına sahip tipik sensör dizi sistemlerinden biraz daha karmaşıktır. Algılama sistemindeki bir optik sensör dört temel bileşenden oluşur: bir ışık kaynağı, ışığı sensöre ve sensörden yönlendirmek için uygun optikler, algılama malzemeleri veya sensör ve sensörden gelen ışık sinyallerini algılamak için bir fotodedektör. Çıkış sinyallerini algılamak için fotodiyotlar, Yük Bağlı Cihaz (*Charge Coupled Device, CCD*) ve Bütünleyici Metal Oksit Yarı İletken (*Complementary Metal Oxide Semiconductor, CMOS*) kameralar kullanılabilir, ancak seçim dikkatli bir şekilde yapılmalı ve hassasiyet, algılanabilirlik, gürültü, spektral tepki ve tepki süresi gibi gerekli özellikler dikkate alınmalıdır.

Optik sensörler genel olarak içsel optik ve dışsal optik sensörler olmak üzere iki türe ayrılabilir. İçsel bir sensör için, gaz halindeki bileşikler, soğurma, emisyon veya rezonans dalga boylarında absorpsiyon, floresans ve kırılma indisi gibi algılama yüzeyindeki optik özelliklerdeki değişiklikler ölçülerek doğrudan tespit edilebilir. Bu fikirden yola çıkarak, dalga kılavuzları yöntemi, yüzey plazmon rezonansı, girişim veya yansıma tabanlı yöntem ve taramalı ışık darbesi tekniği gibi elektronik burunlara uygulanan bazı yaklaşımlar geliştirilmiştir. Harici bir sensör için, bir optik substrat üzerine bağlanarak analiti saptamak için bir gösterge türü kullanılır. Göstergeler, sinyal modülasyonu üretmek için analitle etkileşime giren boyalar, polimerler veya diğer malzemeler olabilir. Kolorimetrik yöntem, bu teoriyi kullanan en yaygın kullanılan tekniktir.




Şekil 2.8. Optik sensör yapısı


e) Piezoelektrik sensörler: Piezoelektrik sensörleri [2], belirli kristallerin uygulanan mekanik gerilimle orantılı bir elektrik potansiyeli ürettiğini belirten piezoelektrik etkiye dayanır. Tersine, bir elektrik potansiyeli uygulandığında, piezoelektrik kristaller mekanik bir deformasyona uğrar ve bu da mekanik bir basınç oluşturabilir. Bu sensörlerde piezoelektrik kristaller, kristallere uygulanan kütle değişimine oldukça duyarlı olan bir rezonans frekansına sahiptir. Piezoelektrik sensörleri, membran kaplı bir piezoelektrik kuvars kristali ve bir elektrik alanı oluşturan iki altın elektrottan oluşur. Uçucu moleküllerin membran yüzeyine adsorpsiyonu, cihazın kütlesini artırarak rezonans frekansının değişmesine neden olur. Kuvars kristal mikro terazi (*Quartz Crystal Microbalance, QCM*) ve yüzey akustik dalga (*Surface Acoustic Wave, SAW*) sensörleri, elektronik burunlarda uygulanan en kullanışlı piezoelektrik sensörlerden ikisidir.

QCM, gelişmiş bir mikro terazi kütle sensörü türüdür. Kuvars malzemenin piezoelektrik özelliklerine dayanan dönüştürücüsü, sensörlerde uygulanmıştır. QCM, karakteristik bir frekansta (10–30 MHz) titreşen, polimer kaplı rezonanslı kuvars diskten

yapılmıştır. Kristal yüzeyinde sınırlayıcı kütle artarken salınım frekansı azalır. Ayrıntılı olarak, gaz moleküllerinin kristal yüzeyinde biriken algılama filmlerine adsorpsiyonu, kuvars kristali (QC) rezonans frekansında kaymaya neden olur. Gaz molekülleri polimer yüzeyine adsorbe edildiğinden rezonans frekansını düşürür ve azalma adsorbe edilen koku kütlesi ile orantılıdır. Metal elektrotlarla (örn. altın) donatılmış QC, QCM sensörünün temel malzemesidir. QCM sensörünün seçiciliği, sensör yüzeyinde kaplanmış hassas malzemelere bağlıdır. Kaplamaların kalınlığı, QCM sensörlerinin hassasiyetini etkiler. Ayrıca sıcaklık, nem ve diğer bazı çevresel koşullar da QCM sensörlerinin hassasiyeti üzerinde etkilidir. SAW ve QCM'nin her ikisi de kütleye duyarlı sensörlerdir. Ancak, SAW bir yüzey akustik dalga sensörü kullanırken, QCM bir Toplu Akustik Dalga (*Bulk Acoustic Wave, BAW*) sensörü kullanır. SAW sensörleri, dalgaların cihazın yüzeyi üzerinde hareket etmesini gerektirir. SAW sensörleri daha yüksek frekanslarda (100-1.000 MHz) çalışır ve bu nedenle frekansta daha büyük bir değişiklik oluşturur. Çıkış dönüştürücüsü ve giriş dönüştürücüsü, SAW'ın temel bileşenleri olan dijital dönüştürücülerdir (IDT'ler). Dönüştürücünün ortamı değiştiğinde, örneğin absorbe edilen gaz molekülleri, titreşim frekansı değişecektir. Dolayısıyla, gaz moleküllerinin ağırlık bilgisi, çıkış IDT'lerinin sinyallerinin giriş IDT'leri ile karşılaştırılmasıyla elde edilebilir. BAW ve SAW sensörlerinin yapısı Şekil 2.9'da, QCM sensörünün yapısı ise Şekil 2.10'da gösterilmektedir.



Şekil 2.9. BAW ve SAW sensörlerinin şematik diyagramları [54].



Şekil 2.10. QCM sensörünün a) önden görünüşü b) yandan görünüşü [60].

Tablo 2.3. E-burun uygulamalarında kullanılan sensörler [37, 55].

Sensör Tipleri	Ölçülen Büyüklük	Duyarlılık	Avantajları	Dezavantajları
Metal Oksit Yarı İletken (MOS)	İletkenlik	5 – 500 ppm	Ucuz, mikro fabrikasyon, yüksek hassasiyet, hızlı yanıt ve kurtarma süresi, ölçüm devresine kolayca entegre edilebilir	Yüksek sıcaklıkta çalışma, yüksek güç tüketimi, kükürt ve zayıf asit zehirlenmesi, taşınabilir sistemlerde sınırlı uygulama, neme duyarlı, sınırlı sensör kaplamaları
İletken Polimer (CP)	İletkenlik	0,1-100 ppm	Mikro fabrikasyon, oda sıcaklığında çalışma, birçok VOC'ye duyarlı, kısa yanıt süresi, çeşitli sensör kaplamaları, ucuz, sensör zehirlenmesine karşı direnç	Neme ve sıcaklığa karşı yüksek hassasiyet, kısa ömür süresi zamanla sensör tepkisi kayması
Kuvars Kristal Mikroterazi (QCM)	Piezoelektrik	1,0 ng kütle değişimi	Düşük maliyet, hızlı tepki süresi, yüksek hassasiyet, çeşitli sensör kaplamaları	Yetersiz tekrar üretilebilirlik, karmaşık devre, zayıf sinyal-gürültü oranı, neme ve sıcaklığa duyarlı
Yüzey Akustik Dalgası (SAW)	Piezoelektrik	1,0 pg kütle değişimi	Yüksek hassasiyet, hızlı yanıt süresi, çeşitli sensör kaplamaları, küçük, ucuz, neredeyse tüm gazlara karşı hassasiyet	Nispeten zayıf sinyal-gürültü performansı, karmaşık devre, yetersiz tekrarlanabilirlik, sıcaklığa duyarlı
Metal Oksit Yarı İletken Alan Etkili Transistör (MOSFET)	Akım-Gerilim	Düşük ppm	Elektronik arayüz devreleri ile entegre, küçük sensör boyutu, ucuz işletme maliyetleri	Çevresel kontrol, sensör sapması, amonyak ve karbondioksit'e karşı düşük hassasiyet gerektirmesi
Optik	Floresans	Düşük ppb	Yüksek elektriksel gürültü bağıışıklığı, çok yüksek hassasiyet, karışımlardaki tek tek bileşiklerin tanımlanması, çok parametrelili algılama yetenekleri	Işık kaynaklarının sınırlı kullanılabilirliği

2.2.3. Örüntü tanıma birimi

Veri hesaplama sistemlerinde, sensör dizisi tarafından üretilen çok değişkenli yanıtın veri işlemesi için örüntü tanıma teknikleri [41, 46, 61] kullanılır. Tanıma süreci, sensör sinyalleri alındıktan ve bilgisayarda saklandıktan sonra başlar. Örüntü tanıma biriminde, aralarında ortak özellik bulunan veri örneklerini bazı tespit edilmiş özellikler aracılığı ile tanımlama veya sınıflandırma işlemi gerçekleştirilir. Arayüz devreleri tarafından üretilen elektrik sinyali, örüntüyü tanımak için genellikle yeterli değildir. Bu sinyaller daha fazla işlenmelidir. Örüntü tanıma birimleri, e-burun sistemlerinin yazılım birimleridir.

Sayısal sinyal tanımlama için ön işleme, öznitelik çıkarma, sınıflandırma/regresyon ve doğrulama aşamalarından geçirilir. Sinyal ön işleme, sensör kaymasını telafi etmeye, sensör dizisi yanıtından tanımlayıcı parametreleri çıkarmaya ve öznitelik vektörünü sonraki işlemler için hazırlamaya odaklanan tüm sürecin ilk aşamasıdır. Ön işleme aşamasında, sensör tepkilerinin referans noktalarının belirlenmesi, sensör tepki alanlarının tüm sensörler için normalleştirilmesi ve sensör tepki örüntülerinin belirlenmesi için gerekli işlemler yapılır. Öznitelik çıkarımı, veri kümesinden örüntüleri tanımaya yardımcı olan özellikleri belirlemek ve veri kümesinin boyutunu azaltmak için kullanılır. Sınıflandırmada öncelikle veri seti düşük boyutlu uzaya dönüştürülür ve daha sonra çeşitli sınıflandırma yöntemleri kullanılarak olası VOC'lerin örüntüleri belirlenir. Sınıflandırma, veri tabanında önceden öğrenilen VOC maddelerinden bilinmeyen bir VOC örneğinin belirlenmesini sağlar. Regresyon, gaz örneklerinin konsantrasyon ve kalite gibi özelliklerini tahmin etmektir. Doğrulama, bir sınıflandırıcının verileri en iyi şekilde sınıflandırması için gereken parametrelerin belirlenmesidir. Bu şekilde genelleme performansı yüksek bir sınıflandırıcı belirlenir.

Örüntü tanıma yöntemleri, denetimli ve denetimsiz öğrenme olarak iki kategoriye ayrılabilir. Denetimli örüntü tanıma için, bilinmeyen bir VOC test edilir ve eğitim örneğinin içerdiği sınıflar hakkında önceden bilgi gerektiren bir bilgi tabanına göre sınıflandırılır. Buna karşılık, denetimsiz yöntemler, karşılık gelen VOC sınıfı açıklamaları olmadan bilinmeyen VOC vektörleri arasında ayırım yaparak, farklı sınıfları tepki vektöründen ayırmayı öğrenirler.

Çalışmada örüntü tanıma ile ilgili kullanılan yöntemler Bölüm 3'te açıklanmaktadır.

3. METODLAR

Bu çalışmada, sensörlerden elde edilen gaz verileri üzerinde çeşitli işlemler yapılarak gaz örnekleriyle ilgili bir veri tabanı oluşturulmuş ve bu veri tabanından yararlanılarak belirlenmesi istenilen gaz örneklerinin analiz edilmesi ve yorumlanması için çeşitli sinyal işleme teknikleri kullanılmıştır. Sinyaller kullanılarak planlanan sınıflandırma ve regresyon süreçleri dört temel aşamadan oluşmaktadır. Birbirine yakından bağlı bu dört aşama sırasıyla ön işleme, öznitelik çıkarma, sınıflandırma ve regresyondur. Bu aşamalar aşağıdaki alt bölümlerde ayrıntılı olarak açıklanmaktadır.

3.1. Ön İşleme

Ön işleme aşaması, örüntü tanıma biriminin ilk adımıdır. Ön işleme [32, 47, 62, 63], veriyi kullanmadan önce daha başarılı sonuçlar elde edebilmek amacıyla verinin bazı işlemlerden geçirilmesidir. E-burun gibi bir çoklu sensör sistemi ile ölçüm yaparken büyük miktarda veri üretilir. Sensörlerin verdiği tepkilerin dinamiklerini açıklamak için her sensörden daha fazla sinyal parametresi hesaplanabilir. Böylece, ilgilenilen özelliklere bağlı olarak veri sayısını azaltmayı gerektiren büyük miktarda veri üretilir. Sensörlerden elde edilen veriler gürültü içerebilir ya da sensör sapması gibi problemler oluşabilir. Bu nedenle, sensör yanıtlarından çıkarılan verilerin genellikle önceden işlenmesi gerekir, öznitelik çıkarımında yanıltıcı etkileri ortadan kaldırmak için örüntü üzerinde bazı işlemler yapılır. Verilerden anlamlı bilgiler elde edilerek kullanım değerleri daha güçlü hale getirilir, öznitelik çıkarma işleminin güvenilirliği artırılır. Analogdan dijitale dönüştürmeye kadar izlenen gürültünün ve anormal veri okumalarının azaltılması sağlanır.

Ön işleme aşamasında, öncelikle verilerin iletkenliğe çevrilmesi işlemi gerçekleştirildi. Sensör tepkilerinin referans noktaları referans düzeltmesi yapılarak ayarlandı, aşağı-örnekleme ile boyut küçültme yapıldı, sensör tepkileri min-maks normalleştirme ile her boyutta 0 ile 1 arasında sınır değerler olacak şekilde sabitlendi ve sensör tepki modellerinin belirlenmesi için gerekli işlemler yapıldı. Sensör yanıtlarından ilgili bilgiler çıkarılarak veriler model analizi için hazır hale getirildi.

Referans düzeltme, işaret ön işleme aşamalarından biridir. Sensörlerden elde edilen ham verilerdeki farklılıkları gidermek için uygulanmıştır. Hepsinin aynı koşullar altında değerlendirilmesi için referans gaz seviyesindeki farklılıklar giderilerek her sinyalin aynı referans noktasından başlaması sağlanmıştır. Çalışmada kullanılan fark referans düzeltme yöntemi aşağıdaki şekilde formüle edilebilir:

$$V_{\bar{o},s}^B(t_k) = V_{\bar{o},s}(t_k) - V_{\bar{o},s}(t_1) \quad \forall \bar{o},s,k \quad (3.1)$$

Burada, $\bar{o}=1\dots N_{\bar{o}}$ VOC örneğini, $k=1\dots N_T$ sensör cevaplarının toplam örnekleme sayısını ve $s=1\dots N_s$ sensör sayısını ifade etmektedir. $V_{\bar{o},s}(t_1)$ sensör yanıtından alınan ilk örnektir, $V_{\bar{o},s}(t_k)$ ise sensör yanıtlarından t anında elde edilen gerilim değerini göstermektedir.

Sensör verilerinden elde edilen bilgilerin iyi bir şekilde ayırt edilebilmesi için veri boyutunun büyük tutulması gerekir. Bununla birlikte, çok büyük ve karmaşık verilerde kendisini tekrar eden ve işe yaramayan bilgiler de yer alabilmektedir. Veri miktarının fazla olması süreci zorlaştırır, hesaplama süresini önemli ölçüde uzatabilir ve sinyalleri sınıflandırırken hedeflenen başarı oranına ulaşmada zorluklara neden olabilir. İşlem yükünü azaltılması, sınıflandırma ve regresyon performansının artırılması ve hataların azaltılması için aşağı-örnekleme kullanılarak boyut küçültme yapılmıştır ve gaz sensörü verilerindeki fazlalıklar giderilerek sınıflandırma işlemine uygun hale getirilmiştir, verilerin karmaşıklığı veya boyutu azaltılmaya çalışılmıştır.

Min-maks normalleştirme ile veriler genel veriler içinde ağırlıklandırılarak kolayca yorumlanmasına olanak sağlanır. Veri normalleştirmesinin arkasında iki motivasyon vardır. Birincisi, değişen büyüklüklerde olabilen çoklu sensör girişleriyle başa çıkmaktır. İkincisi ise yapay sinir ağları gibi birçok örüntü tanıma tekniği için işlem süresi, tüm girdi değişkenleri aynı büyüklükte olduğunda azaltılabilir.

3.2. Sinyal Düzeltme

Sinyal düzeltme [64, 65], zaman serilerindeki mantıksız eğilimleri ortadan kaldırmak için kullanılır, sinyallerden offseti veya eğilimi çıkarır. Ölçülen sinyaller, verilere özgü olmayan genel örüntüler gösterebilir. Bu eğilimler bazen veri analizini engelleyebilir ve kaldırılması gerekir. Çalışmada kullanılan sinyal düzeltme fonksiyonu, düzenli olarak örneklenen veri sinyallerinden ortalamayı veya en uygun çizgiyi (en küçük kareler anlamında) çıkarır. Veriler dört sütun içermektedir ve her bir veri sütununu ayrı ayrı ele alır. Verilerden bir eğilimin çıkarılması, analizin eğilimle ilgili verilerdeki dalgalanmalara odaklanılmasını sağlar. Eğilimler anlamlı olabilse de bazı analiz türleri, eğilimler kaldırıldığında daha iyi kestirim sağlar. Kararlı durum verileri için hem giriş hem de çıkış sinyallerinden ortalama değerlerin ve doğrusal eğilimlerin kaldırılması gerekir. Çalışmada, yöntemin elde edilen sonuçları önemli ölçüde düzeltebildiği görülmüştür.

3.3. Öznitelik Çıkarımı

VOC'leri tanımlamak için gaz bileşenlerinin konsantrasyonları kullanılırsa, her konsantrasyon VOC'nin bir özneliği olarak alınabilir. İdeal olarak, her bir bileşenin konsantrasyonu bulunursa, VOC'ler konsantrasyon vektörü ile ayırt edilebilir. Bu konsantrasyon vektörleri aslında gazların örüntüleridir. Ancak, tüm konsantrasyon vektörünü bulmak zor ve neredeyse imkansızdır. En karmaşık VOC'ler, yüzlerce veya binlerce gaz bileşeninden oluşur. Bir dizi gaz sensörünün uygulandığı e-burnun durumu göz önüne alındığında, tüm konsantrasyon örüntüsünü elde etmek için her sensörün yalnızca belirli bir bileşene yanıt vermesi gerektiği için yüzlerce veya binlerce sensöre ihtiyaç vardır. Bu ideal durum pratikte uygulanamaz. Sensör sayısı, maliyetleri ve boyutları ile sınırlıdır ve mevcut sensörler, bir dizi bileşene yanıt verir. Bir e-burunda, bir sensör dizisinin kullanılması, her bir sensörün belirli bir gazdan ziyade bir gaz aralığına veya sınıfına tepki vermesi gibi kısmen örtüşen hassasiyetle sonuçlanır. Gaz örneklerinin sensörler tarafından algılanması ve sonrasında analiz edilmesi sırasında bilgi karmaşası yaşanabilmektedir. Sadece belirli bir VOC türüne yanıt veren sensörlerin yanı sıra birden fazla VOC türüne yanıt veren sensörler de olduğu için sensör yanıtlarından edindiğimiz bilgiler ilgisiz veriler de içerebilmektedir. Bununla birlikte, ortam sıcaklığı, nem, VOC'lerin sadece elde etmek istediğimiz gaz örneğini içermeyip başka gaz moleküllerini de içermesi gibi durumlar da karmaşık bilgilere neden olabilmektedir. Bu gibi etkilerin ortadan kaldırılması veya en aza indirgenebilmesi için öznitelik çıkarma [63, 66-68] yöntemleri kullanılmaktadır.

Sinyal düzeltme aşamasından sonra, veri setinden örüntü tanımaya yardımcı özellikleri belirlemek ve her örnekten ölçülen veri sayısını azaltmak için öznitelik çıkarımı yapılmaktadır. Sadece yapılmak istenilen işlemle ilgili özneliklerin en iyi kombinasyonu seçilir, diğerleri veriden ayklanır. Bu şekilde, işlem zamanından da kazanç sağlanır. Öznitelik çıkarma işlemlerinde hem veri boyutu küçültülür hem de sınıfların en ayırt edici karakteristik bilgileri tespit edilir. Öznitelik çıkarma yönteminin amacı, daha az veri ile karakteristik sensör yanıtından sağlam bilgileri çıkarmaktır. Bu yöntemle veri daha anlaşılır hale gelir.

Bu çalışmada farklı özneliklerin başarı üzerindeki etkileri incelenmiştir. Özellik çıkarma aşamasında verilere üç farklı yöntem uygulanmıştır. İlk olarak, sensör yanıtlarının maksimum değerleri alınarak öznitelik çıkarma işlemi gerçekleştirilmiştir. İkinci olarak, LSTM ağındaki tam bağlantılı katmanının giriş verileri öznitelik olarak alınmıştır. Son olarak da LSTM ağının tam bağlantılı katmanındaki değerler çıkış olarak alındı ve TCN

modeline giriş olarak verildi ve TCN'deki tam bağlantılı katmanın çıkış verileri öznitelik olarak alındı. Bu öznitelikler yeni öznitelik uzayını oluşturmaktadır. Bu işlemler ile karmaşık ham veri setinden orijinal veriyi temsil eden veri altkümeleri oluşturulmuştur. Çıkarılan öznitelikler arasından veri ile ilgili en iyi öznitelikler seçilerek sınıflandırma ve regresyon başarıları artırılmıştır. Öznitelik çıkarma aşaması, e-burun sisteminin performansında en etkili rollerden birini oynamaktadır. Bu çalışmada, ham veriler, sensör yanıtının maksimum değerleri ve öznitelik olarak derin öğrenme ağlarının tam bağlantılı katman girişleri karşılaştırılarak sınıflandırma ve tahmin başarısına etkisi incelenmektedir.

3.4. Sınıflandırma

Sınıflandırma aşamasında Karar Ağacı, Doğrusal ve Karesel Ayırma Analizi, Naïve Bayes, SVM, k-En Yakın Komşu (*K-Nearest Neighbours*, *KNN*) ve Kolektif (*Ensemble*) Denetimli sınıflandırma algoritmaları kullanılmıştır ve sınıflandırma sonuçları birbirleriyle karşılaştırılmıştır.


Veri seti düşük boyutlu uzaya taşındıktan sonra gaz örneklerine ait örüntüler, çeşitli sınıflandırma yöntemleri kullanılarak belirlenir. Sınıflandırma algoritmaları, veri kümesinde bulunan verileri en az hata ile kendilerine en yakın sınıfa eşleştirirler. Sınıflandırmanın temel amacı, yeni verilerin hangi sınıfa/kategoriye gireceğini belirlemektir. Tahmine dayalı modelleme yapılır. Eğitim kümesinden verilerin dağılım şeklini öğrenirler ve sınıfı belli olmayan test verilerinin doğru bir şekilde sınıflandırılmasını sağlarlar. Sınıflandırmada, öznitelik uzayı veri kümesi üzerindeki sınıfları belirten etiketlere göre karar bölgelerine ayrılmaktadır. Çıkarılan özniteliklerden örüntünün hangi sınıfa ait olacağı belirlenir. Çalışmada da farklı sınıflandırma algoritmaları denenerek, kullanılan veriler için optimum sonucu belirleyen sınıflandırma algoritması belirlenmiştir.

3.4.1. Karar ağacı

Çalışmada, gaz verilerini sınıflandırmak için kullanılan yöntemlerden biri karar ağacı algoritmasıdır [69-72]. Karar kümelerini temsil eden ağaç şeklindeki yapılardır. Bu kararlar, bir veri kümesinin sınıflandırılması için kurallar oluşturur. Sınıflarını bildiğimiz eğitim veri setinden tümevarım yöntemini kullanarak ağaç şeklinde karar yapıları oluşturma işlemine karar ağaçları denir. Karar ağaçları, sınıflandırma, öznitelik ve hedefe göre karar düğümleri (decision nodes), yaprak düğümleri (leaf nodes) ve dallardan oluşan ağaç yapısı formunda bir model oluşturmaktadır. Bir karar düğümü bir veya birden fazla dallanma içerebilir. İlk düğüme kök düğüm (root node) denir. Karar ağaçları, kuralları ve ilişkileri keşfetmek için

veri setinde bulunan bilgileri sistematik olarak parçalayan ve alt bölümlere ayıran bir dizi analitik araçtır. Karar kurallarının oluşturulması kökten başlar ve sınıflar ayrılana kadar, yani yapraklara ulaşana kadar devam eder. Veri tabanından elde edilen karar ağaçlarından hangi sınıfa ait olduğunu bilmediğimiz bir veriye sahip olduğumuzda oluşturulan kural setine göre sınıf tahmin edilmektedir.

Ağaç yapısındaki her değişken, ağaç yapısındaki başka bir düğüme iletir. Karar ağacında üst kısım kök düğüm, alt kısım ise yaprak düğüm olarak adlandırılır. Kök ve yaprak düğümleri arasındaki bölünme dallar olarak adlandırılır. Ağaç yapısındaki her dal, bir kural oluşturan fonksiyondur. Karar ağacı, kök düğümden başlayan ve deneysel birimlere uygulanan evet-hayır cevaplarına göre devam eden yollardan oluşmaktadır. Şekil 3.1’de karar ağacı yapısı gösterilmektedir.



Şekil 3.1. Karar ağacı yapısı [63].

Entropi değişken belirsizliğinin ölçülmesinde kullanılmaktadır. Entropi, 0’a yaklaştıkça belirsizlik azalır ve tahmin de o kadar iyi olur. (3.2)’de entropi denklemi verilmektedir:

$$H = - \sum p(x) \log p(x) \quad (3.2)$$

Burada, H entropiyi ifade ederken, $p(x)$ ise belirli bir sınıfa ait grubun yüzdesini ifade etmektedir.

Entropinin en aza indirgenmesi bölünmelerin ve tahminin başarılı olduğunu göstermektedir. Bilgi kazancı, en iyi bölünmeyi/tahmini belirlemek amacıyla kullanılmaktadır. (3.3)'te bilgi kazancı denklemi verilmektedir:

$$Gain(S, D) = H(S) - \sum_{V \in D} \frac{|V|}{|S|} H(V) \quad (3.3)$$

Burada, orijinal veri kümesi S ile ifade edilirken, S'nin alt kümesi ise V ile ifade edilmektedir. D, kümenin bölünmüş bir parçasıdır.

Bu çalışmada hem ham verilerde hem de öznitelik çıkarımı yapıldığı zaman en iyi sonuçlar ince ağaç algoritması ile elde edilmiştir. Maksimum bölünme sayısı 100 olarak elde edildi.

3.4.2. Doğrusal ve karesel ayırma analizi

Doğrusal ayırma analizi (*Linear Discriminant Analysis, LDA*) [32, 73-76] verilerdeki farklı sınıflara ait grupların lineer ayrılabilirliğini maksimize ederek boyutu küçülten bir yöntemdir. Mevcut veri seti bileşenleri ayırmak için çok uygun olmadığında, verileri daha kolay ayrılabilir hale getirmek için kovaryans matrisini kullanır. Doğrusal ayırma analizinde tüm grupların kovaryans matrislerinin eşit olduğu varsayılır. Hangi gruba ait olduğu belli olmayan örnekler en düşük hata ile ait olduğu gruba atanır. LDA'da sınıf içi örneklerin birbirine olan uzaklığı minimum, örneklerin sınıflar arası uzaklığı ise maksimum olacak şekilde belirlenir. LDA, herhangi bir veri kümesinde sınıflar arası kovaryansın sınıf içi varyansa oranını maksimize eder. Böylece sınıflar başarıyla ayrılır.

Doğrusal ayırma analizinde, boyut indirgeme işleminde sınıflar arası saçılım matrisi ve sınıf içi saçılım matrisi göz önünde bulundurulmaktadır. S_B , sınıflar arası saçılım matrisi, S_W ise sınıf içi saçılım matrisini ifade eder. Veri kümesindeki sınıf sayısı c ile ifade edilirken, veri nesnelerinin ortalama değeri ise $\bar{x}$ ile ifade edilmektedir. Sınıflar arası saçılım matrisi ve sınıf içi saçılım matrislerinin formülasyonları (3.4) ve (3.5) eşitliklerinde verilmektedir.

$$S_B = \sum_{i=1}^c (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T \quad (3.4)$$

$$S_W = \sum_{i=1}^c \sum_{j=1}^{N_i} (\bar{x}_{i,j} - \bar{x})(\bar{x}_{i,j} - \bar{x})^T \quad (3.5)$$

$\bar{x}_i$, i. sınıfın ortalama değeri, $\bar{x}_{i,j}$ ise i. sınıfın j. örneğini ifade etmektedir. i. sınıfın örnek sayısı ise N_i ile ifade edilmektedir.

Sınıflar arası saçılım matrisi ve sınıf içi saçılım matrisinin bulunmasından sonra genelleştirilmiş öz değerler problemi (3.6)'daki gibi çözülür:

$$S_B a = \lambda S_w a \quad (3.6)$$

Farklı sınıfların ortalaması arasındaki mesafe olan S_B hesaplandıktan sonra sınıf içi kovaryans matrislerinin ortalaması S_w hesaplanır. Sonrasında $\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_r$ özdeğerlerine karşılık gelen r tane özvektör ile dönüşüm matrisi oluşturulur.

Kovaryans matrislerinin eşit olmadığı durumlarda, doğrusal ayırma analizi ile oluşturulan ayırma fonksiyonlarının etkinliği azalmaktadır. Karesel ayırma analizinde (*Quadratic Discriminant Analysis, QDA*) [77-79], grupların eşit kovaryans matrislerine sahip olduğu varsayımı yoktur, dolayısıyla her sınıf için ayrı ayrı tahminler yapılır ve bu, doğru bir tahmin için LDA'dan daha fazla veri gerektirir. Sınıfların varyans kovaryans matrislerinin birbirinden farklı olduğu durumlarda veri matrislerinin ayırım analizinde karesel ayırma analizi uygulanmıştır.

Sınıf ortalamalarının tahmini, μ_k ile ifade edilir.

$$\mu_k = \frac{1}{N_k} \sum_{i=1}^{N_k} x_i \quad (3.7)$$

Burada, $x = x_1, x_2, x_3, \dots, x_p$ orijinal değişkenleri ifade etmektedir, N_k , $k = 1, 2, \dots$ sınıfındaki örnek sayısıdır, K ve N toplam örnek sayısıdır. π , dağılımlarının gerçek değerleri bilinmediği için tahmin edilmektedir, eşitliği (3.8)'de verilmektedir.


$$\pi_k = \frac{N_k}{N} \quad (3.8)$$

Karesel ayırma analizi fonksiyonu (3.9)'da gösterildiği gibidir:

$$\delta_k(x) = -\frac{1}{2} \log \left| \frac{1}{N_k} \sum_{i=1}^{N_k} (x_i - \mu_k)(x_i - \mu_k)^T \right| - \frac{1}{2} (x - \mu_k)^T \sum_k^{-1} (x - \mu_k) + \log(\pi_k) \quad (3.9)$$

Karar sınırları x 'teki ikinci dereceden denklemlerdir. QDA genellikle verilere LDA'dan daha iyi uyar, ancak tahmin edilmesi gereken daha fazla parametreye sahiptir.

Bu çalışmada, hem önerilen metotlardan biri olan LSTM'nin tam bağlı katmanından öznetelik çıkarımı yapıldığında, hem de LSTM ve TCN'nin birlikte kullanıldığı önerilen yeni yöntemle en iyi sonuç doğrusal ayırma analizi ile elde edilmiştir.



Şekil 3.2. Eşit sınıf örneklem büyüklüğü ile gösterimler: (a) iki sınıf için LDA, (b) iki sınıf için QDA, (c) iki sınıf için Gauss Naive Bayes, (d) iki sınıf için Bayes, (e) üç sınıf için LDA (f) üç sınıf için QDA, (g) üç sınıf için Gauss Naive Bayes ve (h) üç sınıf için Bayes [78].

3.4.3. Naïve Bayes

Naive Bayes sınıflandırma algoritması [80-82], genellikle sonsal olasılıkları hesaplamak için kullanılan ve iki rastgele olayın koşullu olasılıklarını ilişkilendiren bir hipotezdir. Naive Bayes sınıflandırıcısı, güçlü bir bağımsızlık varsayımı üzerinde çalışır. Bu,

bir özelliğin olasılığının diğerinin olasılığını etkilemediği anlamına gelir. Sonsal olasılık ilkesine dayalı bir teoremdir. Naive Bayes sınıflandırması, en yüksek olasılığa sahip sınıfın örneklerini tahmin eden olasılık yöntemlerinden biridir. Verilerin belirli bir sınıfa ait olduğu hipotezi vardır. Daha sonra hipotezin doğru olma olasılığı hesaplanır. Bu, belirli problem türleri için en pratik yaklaşımlardan biridir. Yaklaşım, tüm verilerin yalnızca bir kez taranmasını gerektirir. Ayrıca, bir aşamada ek eğitim verileri varsa, o zaman her eğitim örneği hipotezin doğru olma olasılığını aşamalı olarak artırabilir veya azaltabilir. Bu nedenle, belirsizlik içeren bir alanı modellemek için Bayes ağı kullanılır. Ön bilgiler, gözlemlenen verilerle birleştirilebilir. Naive Bayes sınıflandırma algoritması, Bayes Teoremine dayanan istatistiksel yöntemlerden biridir. Bayes kuralı:

$$P(C_i | X) = P(X | C_i) \cdot \frac{P(C_i)}{P(X)} \quad (3.10)$$

C_i , i. sınıfı temsil eder. X , bilinmeyen verileri temsil eder ve en yüksek olasılık sonuçlarına göre bir sınıfa aittir. Bu çalışmada önerilen yeni yöntemle en iyi sonuç Gauss Naive Bayes ile elde edilmiştir ve çekirdek tipi Gauss'tur. Tahmin ediciler sürekli bir değer aldığı ve ayrık olmadığı, bu değerlerin bir gauss dağılımından örneklendiği varsayılmaktadır. Şekil 3.2'de iki sınıf ve üç sınıf için LDA ve Bayes gösterimleri yer almaktadır.


3.4.4. Destek vektör makineleri (Support Vector Machines, SVM)

SVM [45, 83-87], doğrusal veya doğrusal olmayan bir fonksiyon yardımıyla sınıflandırma yaparken verileri ayırt etmek için en uygun fonksiyonun tahmin edilmesi esasına dayanır. SVM, veri noktalarını, düzlem ile eğitim kümesi içindeki herhangi bir nokta arasında mümkün olan en büyük marja sahip sınıflara bölen bir çizgi veya düzlem oluşturur ve yeni verilerin doğru bir şekilde sınıflandırılmasını sağlar. Veri noktaları, çekirdek oluşturma olarak bilinen bir süreçte, onları ayırmak için bir hiper düzlem oluşturulana kadar aşamalı olarak daha yüksek boyutlara eşlenir.

SVM'nin temel amacı, veri sınıflarının sınırları arasındaki mesafeyi maksimum yapan en uygun karar sınırını bulmaktır. Bu algoritma, destek vektörleri denilen ve her bir sınıfın sınırlarını belirleyen verileri tanımlayarak bu işlemi gerçekleştirmektedir. İki boyutlu uzayda verilerin birbirinden ayrılması için doğrular kullanılırken, çok boyutlu uzayda bu doğruların yerini hiper düzlemler almaktadır. Verilerdeki sınıfların ayrılması, çok boyutlu bir alanda en yüksek marjın bulunması ve SVM kullanılarak en uygun hiper düzlemin oluşturulmasıyla

sağlanır. Hiper düzlemlerin yerleşimi, hiper düzlem ile sınıflar arasındaki sınıra en yakın birkaç nokta arasındaki mesafenin en aza indirilmesiyle belirlenir. Hiper düzlem arayışı tipik olarak eşitsizlik kısıtlamaları ile amaç fonksiyonunu (marj) çözerek, Lagrange çarpanı yöntemini kullanarak ve Karush-Kuhn-Tucker (KKT) koşullarını (çözüm için gerekli ve yeterli) uygulayarak elde edilir. Bu adımda, SVM eğitilir. Hiper düzlem belirlendikten sonra, sınıflandırılmamış veriler SVM alanına yansıtılır ve hiper düzlemdeki konumlarına göre sınıflandırılır. Şekil 3.3'te, SVM yönteminde hiper düzlemin belirlenmesi ile ilgili gösterimler yer almaktadır. SVM, aykırı değerlere karşı dayanıklılık gösteren ve yüksek boyutlu öznelik uzaylarında iyi performans gösteren bir algoritmadır. Yaygın olarak kullanılan çekirdek fonksiyonları arasında doğrusal, doğrusal olmayan, polinom, Gauss çekirdeği, Radyal temel işlev (RBF) ve sigmoid bulunur.

Çalışmada önerilen yönteme göre LSTM ve TCN birlikte kullanılarak öznelik çıkarımı yapıldığında en başarılı sonuç ikinci dereceden çekirdek fonksiyonu ile elde edilmiştir. Çok sınıflı verileri ayırmak için kullanılan yöntem ise bire karşı birdir (one versus one).



Şekil 3.3. SVM yönteminde hiper düzlemin belirlenmesi (a) doğrusal olarak ayrılabilen veri örnekleri (b) doğrusal olarak ayrılamayan veri örnekleri [87].

SVM algoritmalarında, doğrusal olarak ayrılabilen örnekler için k sayıda örnekten oluşan iki sınıflı bir eğitim verisinde $\{x_j, y_j\}$, $j=1, \dots, k$ olduğu kabul edilmektedir ve optimum hiper-düzlemin oluşturulması için kullanılan eşitsizlikler (3.11) ve (3.12)'de verilmektedir.

$$w \cdot x_j + b \geq +1 \quad \forall y=+1 \quad (3.11)$$

$$w \cdot x_j + b \leq +1 \quad \forall y = -1 \quad (3.12)$$

Bu eşitsizliklerde, $x \in R^N$ 'de N boyutlu bir uzayı ifade etmektedir, sınıf etiketleri $y \in \{-1, +1\}$ 'dir.

Ağırlık vektörü w , eğilim değeri ise b ile gösterilmektedir. Hiper düzlemleri oluşturan destek vektörleri (3.13)'teki eşitlikte verilmektedir.

$$w \cdot x_j + b = \pm 1 \quad (3.13)$$

Sınırlamalar, (3.14)'teki eşitliğe göre bulunmaktadır:

$$y_j(w \cdot x_j + b) - 1 \geq 0 \quad y_j \in \{1, -1\} \quad (3.14)$$

(3.15) eşitliğinde verilen Lagrange denklemleri kullanılarak optimizasyon problemi çözülmektedir. Denklemdaki α_j ifadesi pozitif Lagrange çarpanıdır.

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{j=1}^k \alpha_j y_j (w \cdot x_j + b) + \sum_{j=1}^k \alpha_j \quad (3.15)$$

KKT koşulları kullanılarak (3.15)'te verilen eşitlik sadeleştirilir ve (3.16) eşitliği elde edilir.

$$L_d = \sum_{j=1}^k \alpha_j - \frac{1}{2} \sum_{j,i} \alpha_j \alpha_i y_j y_i x_j x_i \quad \alpha_j > 0, \forall_j \quad (3.16)$$

(3.16) eşitliğinin çözümünde, Lagrange çarpanlarının birçoğu sıfır olur, geriye kalan pozitif α_j değerli x_j vektörleri destek vektörlerini oluşturur.

Doğrusal olarak ayrılamayan veriler için optimum hiper-düzlemin oluşturulması için kullanılan eşitsizliklere, ξ_j eğitim hatası sapması da eklenerek (3.17), (3.18) ve (3.19)'de verilen denklemler elde edilir.

$$w \cdot x_j + b \geq +1 - \xi_j \quad \forall y = +1 \quad (3.17)$$

$$w \cdot x_j + b \leq -1 + \xi_j \quad \forall y = -1 \quad (3.18)$$

$$\xi_j \geq 0, \forall_j \quad (3.19)$$

(3.20) eşitliğinde verilen Lagrange denklemlerinde μ_j değeri, ξ_j değerinin pozitif olmasını sağlamaktadır.

$$L_p = \frac{1}{2} \|w\|^2 - C \sum_{j=1}^k \xi_j - \sum_{j=1}^k \alpha_j \{y_j(w \cdot x_j + b) - 1 + \xi_j\} - \sum_{j=1}^k \mu_j \xi_j \quad (3.20)$$

KKT koşulları kullanılarak (3.20)'de verilen eşitlik sadeleştirilir ve (3.21) eşitliği elde edilir.

$$L_d = \sum_{j=1}^k \alpha_j - \frac{1}{2} \sum_{j,i} \alpha_j \alpha_i y_j y_i x_j x_i \quad 0 < \alpha_j < C, \forall_j \quad (3.21)$$

Bu denklemde, $0 < \alpha_j < C, \forall_j$ aralığında bulunan pozitif α_j değerli x_j vektörleri destek vektörlerini oluşturmaktadır.

3.4.5. K-en yakın komşu algoritması (K-Nearest Neighbours, KNN)

KNN sınıflandırma yöntemi [47, 88-91], mesafeye dayalı bir sınıflandırıcıdır. Benzer örnekler sınıftaki diğer örneklerin yanındadır ve benzer olmayan örnekler sınıftaki diğer nesnelerden uzaktır. Dolayısıyla, farklılıklarının ölçümü, iki örnek arasındaki mesafedir. Eğitim süresinde, KNN algoritması, öznitelik setinden örneklerin arasındaki mesafeleri hesaplayan bir süreci içermektedir. En yakın komşular bize bu örnekler için en küçük mesafeleri verir. Öklid, Minkowski veya Mahalanobis ölçüm türleri örnekler arasındaki mesafeyi hesaplamak için kullanılır. Bu çalışmada, (3.22)'de eşitliği verilen Öklid uzaklığı ile mesafe hesaplaması yapılmıştır.

$$|A - B| = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.22)$$

Sınıf, öznitelik uzayında k-en yakın komşuların en yaygın sınıfı olarak tahmin edilmektedir. En yakın k eğitim verisinin sınıfına göre test örneğinin sınıfı belirlenir. Sistemi test etmek için kullanılan veriler, yakın olduğu sınıfa ait kabul edilir. Sınıflandırılmak istenen veri, eğitim veri setindeki en yakın k adet komşu en fazla hangi sınıfa ait ise o sınıfa atanır. KNN algoritmasının performansı, metrik mesafeye ve en yakın eğitim örnek numarası

olan k 'ye bağlıdır. KNN, basit ama güçlü parametrik olmayan sınıflandırma sistemleridir. Çalışmada öznitelik çıkarımının yapıldığı tüm yöntemlerde komşu sayısı (k) 10 ve uzaklık ölçüsü Öklid'dir.

K-en yakın komşularının nasıl hesaplanacağına ilişkin algoritma aşağıdaki gibidir:

1. Önce, K en yakın komşu sayısı parametresi önceden belirlenir. Gereksinimlere göre K farklı değerler alabilir.


2. İkinci olarak, test örneği ile tüm eğitim örnekleri arasındaki mesafe hesaplanır. İsteğe bağlı olarak herhangi bir mesafe algoritması uygulanabilir.

3. Daha sonra, tüm eğitim örnekleri için mesafeler sıralanır ve K 'inci minimum mesafeye göre en yakın komşu belirlenir.

4. Ardından, bu yöntem denetimli öğrenme olduğu için K 'nin altına düşen sıralanmış değer için eğitim verilerinin tüm kategorileri alınır.

5. Son olarak, tahmin değeri olarak en yakın komşuların çoğunluğu kullanılır.


Şekil 3.4'te gösterilen örnekte, öznitelik alanı iki boyutludur (x_1 ve x_2 değişkenleriyle) ve k 'nin değeri 4'tür. KNN'de, atama için kullanılan komşu sayısı k , bir hiper parametredir; yani eğitim süreci sırasında optimize edilmemiş bir model parametresidir. Şekil 3.4'teki KNN ve SVM sınıflandırma yöntemlerinin karşılaştırıldığında, KNN'de, gri noktanın atanmasına katkıda bulunan en yakın dört komşu gösterilmektedir. Gri noktanın sınıflandırılması, mavi yıldız sınıfıdır. Doğrusal olmayan çekirdeğe sahip varsayımsal SVM'de ise, yeni veriler için noktanın hangi bölgede olduğu sınıflandırılır. Her iki örnekte de öznitelik uzayı iki boyuttan oluşmaktadır.



Şekil 3.4. KNN ve SVM sınıflandırma yöntemlerinin karşılaştırılması [91].

3.4.6. Kolektif öğrenme (Ensemble learning)

Kolektif öğrenme yöntemi [92, 93, 168], bir verinin en yüksek başarı oranını veren bir algoritmadan ziyade, birçok algoritmanın bir arada oluşturduğu bir topluluk ile verilerin sınıflandırılmasına dayanmaktadır. Zayıf regresyon ve sınıflandırma kurallarının performansını iyileştirmek için kullanılan birleştirme teknikleridir. Farklı öznitelik kümeleri ve sınıflandırma algoritmaları birleştirilerek yüksek sınıflandırma performansı elde edilmesi amaçlanmaktadır. Her sınıflandırma algoritması tarafından gerçekleştirilen oylama işlemi ile sınıflandırmanın yönü seçilir. Başka yöntemler olmakla birlikte, yaygın olarak kullanılan yöntemler Torbalama (*Bagging*), Yükseltme (*Boosting*) ve Rastgele Alt Uzay (*Random Subspace*) yöntemleridir. Bu algoritmaların hepsi eğitim veri setini değiştirir, bu değiştirilmiş eğitim setlerinde sınıflandırıcılar oluşturur ve ardından bunları basit veya ağırlıklı çoğunluk oyu ile nihai bir karar kuralında birleştirir. Ancak, farklı bir şekilde performans gösterirler. Şekil 3.5'te kolektif öğrenme algoritmasının genel yapısı gösterilmektedir.



Şekil 3.5. Kolektif Öğrenme Yönteminin Genel Yapısı [94].


3.4.6.1. Torbalama (Bootstrap Aggregation, Bagging) yöntemi

Torbalama yönteminde [94-97], eğitim verilerinin farklı bölümleri ile eğitilen sınıflandırıcılar bir araya getirilir. Bu yöntem, rastgele veri kümeleri oluşturarak modelleri paralel olarak eğitir. Torbalama yönteminin amacı, yeni veri setleri türeterek farklılıklar yaratmak ve böylece genel sınıflandırma başarısını arttırmaktır. Torbalama algoritmaları, toplama yoluyla varyansı azaltarak tahminleri iyileştirir.

Bu yöntemde, regresyon ağaçları oluşturulurken orijinal veri seti ile aynı büyüklükte bir eğitim seti oluşturulur. Bu eğitim setinde bazı öğeler atlanabilirken, diğerleri tekrar tekrar kullanılabilir ve eğitim setinin birden çok sürümü oluşturulur. Bu veri setlerinin her biri,

farklı bir bileşen sınıflandırıcıyı eğitmek için kullanılır ve her bir bileşen sınıflandırıcının ortalaması veya oyu temel alınarak nihai sınıflandırma kararı verilir.

Eğitim verilerindeki küçük değişiklikler doğrulukta nispeten büyük değişikliklere yol açıyorsa, bir sınıflandırıcı/öğrenme algoritması kombinasyonu kararsız olarak adlandırılır. Genel olarak, torbalama, bu tür süreksizliklerin etkin bir şekilde ortalamasını aldığından, kararsız sınıflandırıcılar için tanımayı geliştirir. Torbalamadaki karar kuralı, çoğunlukla bileşen sınıflandırıcılar arasında basit bir oylama ile oluşan bileşen sınıflandırıcıların çıktılarını birleştirmenin veya entegre etmenin en temel yöntemidir. Rastgele orman (*Random Forest, RF*) torbalama yöntemine örnek bir algoritmadır. RF, bir topluluk oluşturmak için birlikte çalışan birçok bireysel karar ağacından oluşur. RF, eğitim setinde rastgele yeniden örnekleme ile oluşturulan, eğitim seti ile aynı boyuttaki veri setleri üzerinde eğitilmiş bir Sınıflandırma ve Regresyon Ağaçları topluluğudur (CART). Şekil 3.6'dan da görüldüğü gibi torbalama yönteminde veriler paralel olarak eğitilmektedir.




Şekil 3.6. Torbalama (*Bagging*) yönteminin yapısı [94].

Çalışmada, ham verilerde, öznitelik olarak maksimum değerler seçildiğinde ya da öznitelik çıkarımında LSTM ve TCN'nin birlikte kullanıldığı önerilen yöntemde topluluk öğrenmesi algoritması olarak torbalama kullanılmıştır. Öğrenme tipi, maksimum bölme sayısı ve öğrenen sayısı sırasıyla karar ağacı 1279 ve 30 olarak seçilmiştir.

3.4.6.2. Yükseltme (Boosting) yöntemi

Yükseltme tekniği [92, 98, 99], öğrenme algoritmasının performansını arttırmak için geliştirilmiş bir topluluk öğrenme tekniği yaklaşımıdır. Yükseltme algoritmasında, eğitim

kümelerinin ve sınıflandırıcıların algoritmanın önceki adımından rastgele ve bağımsız, paralel olarak elde edildiği torbalamanın aksine hem eğitim veri setleri hem de sınıflandırıcılar algoritmada sıralı olarak elde edilir. Güçlendirmenin her adımında, eğitim verileri, yanlış sınıflandırılan örneklerin yeni, değiştirilmiş bir eğitim setinde daha büyük ağırlıklar alacağı şekilde yeniden ağırlıklandırılır. Buna göre de yanlış sınıflandırılan veriler sürekli tekrarlandığı için başarı oranı artar ve doğru sınıflandırma sağlanır. Şekil 3.7’de yükseltme yönteminin yapısı gösterilmektedir. Yükseltme yönteminde amaç, zayıf öğrenme modellerinin güçlendirilmesini sağlamaktır. Uyumlu artırıcı (Adaboost), Eğitim Artırma (*Gradient Boosting*), Aşırı Eğitim Artırma (*Extreme Gradient Boosting, XGBoost*), Hafif Gradyan Artırma Makinesi (*Light Gradient-Boosting Machine, Light GBM*), Kategori Yükseltme (*Category Boosting, CatBoost*) bu yöntemi kullanan algoritmalar.



Şekil 3.7. Yükseltme (*Boosting*) yönteminin yapısı [94].

3.4.6.3. Rastgele Alt Uzay (Random Subspace)

Rastgele alt uzay algoritmasında [92, 93, 98, 100], eğitim setinin veri uzayı yerine özniteliklerin uzayı kullanılır. Çıkarılan öznitelikler arasından rastgele seçim yapılarak modeller eğitilir ve yapı oluşturulur. Eğitim sonuçları, sınıflandırıcıların algoritmalarının bu alt uzaylar üzerinde eğitilmesiyle elde edilir. Amaç rastgele hatayı azaltmaktır.

Öznitelik Torbalama olarak da bilinen RF, verilen sinyalleri doğru bir şekilde sınıflandırmak için bilgilendirici özniteliklerin alt kümesini bulmada önemli bir rol oynayan, en sık kullanılan topluluk öğrenme yöntemlerinden biridir. Yöntem, test örneklerini seçilen bir sınıflandırıcı ile tüm olası özniteliklerin rastgele seçilmiş alt kümeleriyle yinelemeli ve değiştirmeli olarak sınıflandırarak uygulanır. Öznitelik tabanı, her yinelemede aynı sayıda

rastgele izin verilen özniteliklerle değiştirilir. W öznitelik sayısı ve S seçilecek öznitelik sayısı olsun ($S < W$). Her bir alt uzayda S özniteliğinin rastgele seçildiği bu özniteliklerin K alt uzayı oluşturulur. Alt uzay sınıflandırıcılarının her biri, görel olarak seçilen öznitelikler kullanılarak eğitilir ve öğrenilen modeli kullanarak görünmeyen test verileri için etiketleri tahmin eder. K tane alt uzay olduğu için, K ayrı sınıflandırıcı ve bunların görünmeyen test veri kümeleri üzerindeki tahminleri vardır. Bu yöntemin avantajı, yüksek boyutlu verilerde meydana gelebilecek sorunların azaltılmasını sağlamasıdır.

LSTM ağının tam bağlı katmanından elde edilen değerler öznitelik olarak seçildiğinde, topluluk yöntemi, öğrenen tipi, öğrenen sayısı ve alt uzay boyutu sırasıyla alt uzay, en yakın komşular, 30 ve 6 olarak alınmıştır.

3.5. Regresyon

Regresyon [72, 91], çıktının sürekli değere sahip olduğu tahmin için kullanılan denetimli bir öğrenme yöntemidir. Algoritmayı kontrol etmek için her zaman gözleme yanıt olarak bir çıktı değeri vardır. Burada istenilen çıktı değeri sürekli değişkenlerden oluşuyorsa bu öğrenme problemi regresyon olarak adlandırılır. Regresyon algoritmalarında amaç, kesikli veya sürekli değişkenleri tahmin etmektir. Bazı durumlarda, tahminler öznitelikler arasındaki doğrusal ilişkiyi açıklamak için kullanılabilir.

Regresyon analizi ile değişkenler arasındaki ilişkinin varlığı, varsa bu ilişkinin gücü hakkında bilgi edinilebilir. Regresyon analizi yapılırken gözlem değerlerinin ve etkilenen olayların matematiksel bir temsille yani bir fonksiyon yardımıyla gösterilmesi gerekmektedir. Bu modele regresyon modeli denir. Bununla birlikte, regresyon analizi, iki veya daha fazla değişken arasındaki temel ilişkiyi belirlemek için kullanılan, çıkarım ve tahmin için kullanılan bir yöntemdir.

Bu tanımlamalar ve tahminler, modelin bilinmeyen parametreleri tahmin edilerek yapılır. Basit bir regresyon örneği, $y = mx + b$ biçimindeki doğrusal bir modele uygundur; burada x girdi değişkenine dayalı olarak y çıktı değişkeninin tahmini için bir model oluşturulur ve m ve b katsayıları verilerden öğrenilir. Öğrenme tipik olarak en küçük kareler regresyon yaklaşımıyla yapılır ve hataların kareleri toplamını en aza indirir.

Sınıflandırma aşamasından sonra gazların konsantrasyon değerlerine göre regresyon yapılmıştır. İlk önce gaz türü sınıflandırması yapılmıştır ve daha sonra gazların konsantrasyonları tanımlanmıştır. Regresyon çalışmaları ile gaz örneklerinin her bir konsantrasyon değerine ne kadar yakın olduğu bulunmaya çalışılmıştır. Çalışmada Doğrusal SVR, Gauss SVR, Karar Ağacı Regresyonu, Kolektif Öğrenme Regresyonu, Gauss Süreci

Regresyonu ve Doğrusal Regresyon yöntemleri kullanılarak konsantrasyon değerlerine göre her bir gazın ortalama karesel hataları bulunmuştur.

3.5.1. Doğrusal Destek Vektör Regresyonu (Support Vector Regression, SVR)

Sınıflandırma problemlerinde başarılı bir şekilde uygulanan SVM, alternatif bir kayıp fonksiyonu vererek regresyon problemlerine uygulanabilmektedir. Çekirdek fonksiyonlarına dayandığı için parametrik olmayan bir tekniktir. ε toleranslı kayıp fonksiyonu, SVR’de [85, 101-105] kullanılmaktadır. SVR’de, eğitim noktaları ile regresyon hiper düzlemi arasındaki ε ’dan küçük hatalar görmezden gelinmekte ve bazı veriler ε toleranslı kayıp fonksiyonu ile hatalı olarak temsil edilebilmektedirler. Regresyon hiper düzlemi etrafında bir tolerans marjı oluşturulmaktadır, hatası ε ’dan küçük veya eşit olan verilerdeki sapma önemsenmemekte ve hatasız olarak kabul edilmektedir. Bu marjın dışında kalan hatalar ξ_i , ξ_i^* olarak gösterilmektedir, bir düzenlileştirme terimi (C) ile ölçeklendirilmekte ve kayıp fonksiyonunda hatalı olarak kabul edilmektedir. ε toleranslı kayıp fonksiyonu sayesinde, regresyon problemindeki maksimum eğitim hatası, optimizasyon probleminin başında belirlenebilir. SVR’nin amacı, gerçek çıkış değerlerinin en fazla ε sapma ile tahmin edildiği ve bulunan fonksiyona paralel olan ve bununla birlikte eğitim girdilerini içeren iki düzlem arasındaki mesafenin en az olduğu bir fonksiyon bulmaktır. Tahmin fonksiyonu (3.23) eşitliğindeki gibi tanımlanır. Denklemden, tahminlerin (y), D-boyutlu giriş öznitelik uzayının (x) bir fonksiyonu olarak yazıldığı doğrusal bir durumda regresyon hiper düzleminin denklemini gösterir.

$$f(x) = w \cdot x + b \quad w \in R^D, b \in R \quad (3.23)$$

Burada, w ağırlık vektörünü, b ise eğilim değerini temsil etmektedir. $\|w\|^2$ minimize edilerek (3.23) eşitliğinde verilen fonksiyonun düz olması sağlanabilir.

Hata minimizasyon probleminin giderilmesi ve en iyi regresyon doğrusunun bulunabilmesi için (3.24) eşitliğinin çözülmesi gerekir.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (3.24)$$

Kayıp fonksiyonun kısıtlayıcı koşulları, (3.25) eşitliğinde verildiği gibidir:


$$\begin{aligned}
y_i - w \cdot x_i - b &\leq \varepsilon + \xi_i & i = 1, 2, \dots, N \\
w \cdot x_i + b - y_i &\leq \varepsilon + \xi_i^* & i = 1, 2, \dots, N \\
\xi_i, \xi_i^* &\geq 0 & i = 1, 2, \dots, N
\end{aligned} \tag{3.25}$$

(3.24) eşitliği, SVR algoritmasının kayıp fonksiyonunu temsil etmektedir. Burada, C düzenleme faktörüdür ve ξ_i, ξ_i^* tolerans marjı dışındaki hatalardır. (3.24)'te w 'yi en aza indirerek, eğitim verilerine daha düz bir hiper düzlem uydurarak ezberleme riski azaltılır. C değeri, kayıp fonksiyonundaki hatalara ne kadar ağırlık verildiğini belirler. C için küçük bir değer, hataların etkisini en aza indirecek ve bu nedenle daha düz bir regresyon hiper düzlemi ile sonuçlanacaktır. Buna karşılık, C için büyük bir değer, hataların etkisini büyütecek, ezberlemeye ve görünmeyen verilerden kötü tahminler üretmeye yatkın karmaşık bir hiper düzleme neden olacaktır.

Konveks optimizasyon problemi (3.26) eşitliğindeki gibi ifade edilir.

$$\min \frac{1}{2} \|w\|^2 \quad y_i - (w \cdot x_i + b) \leq \varepsilon \quad (w \cdot x_i + b) - y_i \leq \varepsilon \tag{3.26}$$

w ağırlık vektörleri, x_i örneklerinin doğrusal kombinasyonu olarak ifade edilebilmektedir.



Şekil 3.8. Doğrusal SVR'de regresyon hiper düzlemi ve marjı [106]

3.5.2. Karar Ağacı Regresyonu (Decision Tree regression)

Ağaç tabanlı makine öğrenimi yöntemleri, regresyon [107-111] veya sınıflandırma ile hedeflenen çıktıyı tahmin etmek için mühendislik problemlerine sıklıkla uygulanmaktadır. Karar ağaçları, ağaçtaki her bir dalı veya düğümü tanımlayan bir dizi kurala dayalı olarak

verileri yinelemeli olarak bölümlere ayıran yapılardır. Bir karar ağacı, düğümlerde homojenlik açısından mümkün olan en iyi verilere sahip olmak için verileri kökten yapraklara alt kümelerle ayırır. Bu teknik genellikle sınıflandırma görevleri için kullanılsa da yinelemeli bölümlenme olarak da bilinen sayısal değerler üzerinde tahminler yapmak amacıyla regresyon için de kullanılmaktadır. Regresyon işleminde, tahmin edilecek olan hedef öznitelik verileri sürekli değişkenlerden oluşur. Karar ağacı regresyonu algoritması, ağaç yapısı kullanılarak bağımlı bir değişkenin sayısal değerlerinin tahmin edilmesi yöntemidir. Karar değişkenleri ağacın düğümlerinde bulunurken, tahmin edilen hedef değerler ise yapraklarda bulunur.

Karar ağacı regresyon süreçlerinde bilgi kazancı yerine standart sapma (3.27) kullanılır. Hedef için standart sapma hesaplandıktan sonra, öznitelik ve hedef çiftleri için standart sapmalar hesaplanır. İki parametrelili standart sapmanın hesaplanmasında (3.28) ve (3.29) formülasyonları kullanılır. En büyük SDR değerine sahip öznitelik kök olarak belirlenir. Bu durumda, veriler yeniden işlenir. Yinelemeli olarak, tüm alt düğümler hesaplanır ve karar ağacı elde edilir.

$$S = \sqrt{\frac{\sum (x - \mu)^2}{n}} \quad (3.27)$$

$$S(T, X) = \sum_{c \in X} P(c) S(c) \quad (3.28)$$


$$SDR(T, X) = S(T) - S(T, X) \quad (3.29)$$

3.5.3. Kolektif Öğrenme Regresyonu (Ensemble Learning Regression)

Topluluk öğrenmesi regresyonları [110, 112, 113] birden fazla regresyon algoritmasının birleşip en uygun sonucun bulunduğu modellerdir. Bir regresyon topluluğu, çoklu regresyon algoritmalarının ağırlıklı bir kombinasyonundan oluşan tahmin edici bir modeldir. Genel olarak, çoklu regresyon yöntemlerinin birleştirilmesi, tahmin performansını artırır. Topluluk Regresyonunda kullanılan bazı yöntemler şunlardır:

Torbalama (*Bagging*) regresyonunda, orijinal veri kümesinden rastgele alt kümeler oluşturulur. Rastgele seçilen örneklerden bazıları çoğaltılır ve eğitim veri seti 100%'e tamamlanır. Böylece, birbirinden farklı eğitim setleri elde edilir. Regresyon probleminde,

tahmin ediciler eğitildikten sonra, tahminlerin ortalaması alınır ve tahminler birleştirilir. Şekil 3.9’da torbalama regresyon algoritmasının yapısı gösterilmektedir.



Şekil 3.9. Torbalama algoritması [114]

Rastgele orman regresyonunda (*Random Forest Regression, RFR*) birden fazla karar ağacı oluşturulur ve aralarından en iyi sonuç seçilir. Rastgele seçilmiş alt veri setlerine karar ağacı regresyon algoritması uygulanır ve ağaçlar oluşturur. Tahmin sırasında, oluşturulan ağaçlara birer tahmin değeri ürettirilir. Daha sonra, üretilen bu tahmin değerlerinin ortalaması alınır ve böylece kendi tahmin değerini oluşturur.

Yığın regresyonda (*Stacking Regression, STCKR*), tahmin sonucunun iyileştirilmesi için birden fazla regresyon algoritması tüm veri kümesi kullanılarak eğitilir ve bunun sonucunda tahminler üretilir. Önceki veri seti kullanılarak, tahminlerle yeni bir veri kümesi üretildikten sonra bir regresyon modeli yeni veri kümesi ile son tahminlerin üretilmesinde kullanılmaktadır.

Uyumlu artırıcı regresyonda (*Adaboost Regression, ADBR*) karar ağacı regresyonu eğitim seti üzerinde eğitilir ve tahmin yapılır. Daha sonra, bir sonraki regresyon işleminde ilk regresyonda yanlış tahmin edilen verilerin eğitim verilerinin göreceli ağırlığı artırılır ve veri seti bu artırılmış ağırlıklar ile eğitilir ve tekrar tahmin yapılır. Ağırlıklar yine güncellenir ve durma koşulu oluşana kadar regresyon işlemi bu şekilde devam edilir.

Gradyan artırılmış regresyon (*Gradient Boosting Regression, GRBR*) algoritması, birçok regresyon ağacını ileriye doğru aşamalı bir şekilde optimize eden bir ek topluluk

öğrenme yöntemidir. Algoritmada, temel regresyon modeli veri kümesi ile eğitilir. Yeni tahmin ediciler, önceki tahmin ediciler tarafından yapılan hatalardan öğrendiği güçlendirme tekniğini kullanır. Tahmin edilen hata değerleri, sonraki tahmin edilen değerlere eklenir. Ağaçlar bağımsız olarak değil, sırayla eğitilir. En iyi ayrılma noktaları seçilerek ağaçlar oluşturulur ve kayıp en aza indirilir. Modellerdeki ağaçlar değiştirilmez ve yeni ağaçlar teker teker eklenir. Yeni ağaçlar için, kaybı en aza indirmek için bir gradyan iniş prosedürü uygulanır. Yeni ağacın çıktısı, modelin nihai çıktısını artırmak için mevcut ağaç serisinin çıktısına eklenir. Zayıf tahmin ediciler birbiri ardına eklenerek mevcut tahmin edicinin eksiklikleri giderilir ve zayıf tahmin edicilerin birleşimiyle güçlü bir öğrenici oluşturulur. Son ağaç modelinin tahminleri, önceki ağaç topluluklarının yaptığı tahminlerin ağırlıklı toplamıdır.

3.5.4. Gauss Süreci Regresyonu (Gaussian Process Regression)

Bir Gauss Süreci, ortak bir olasılık yoğunluk fonksiyonu olarak çok değişkenli bir Gauss dağılımına sahip olan sonlu sayıda rastgele değişkenin bir koleksiyonudur. Gauss Süreci, denetimli öğrenme kapsamında, giriş çıkış verilerini ilişkilendirmek için doğrusal olmayan ve parametrik olmayan bir Bayes yaklaşımıdır. Gauss Süreci Regresyonunda (*Gaussian Process Regression, GPR*) [115-121], girdi özelliklerini hedef değişkene eşleyen fonksiyonlar üzerinde bir sonsal dağılım, önsel bir dağılımdan ve eğitim verilerinin olasılığından Bayes çıkarımı ile elde edilir. Hedef değişken sıfır etrafında ortalanabildiğinde, önsel dağılımın ortalaması genellikle sıfıra ayarlanır. Gauss süreci regresyon modelleri, çekirdek tabanlı olasılıksal modellerdir. Kovaryans matrisi, veri noktaları arasındaki bağımlılığı mesafelerine göre modelleyen bir Kernel (çekirdek) fonksiyonu kullanılarak tanımlanır. Çekirdek fonksiyonunun seçimi, ortaya çıkan fonksiyonların şeklini belirler.

GPR, ortak bir Gauss dağılımına sahip rastgele değişkenler kümesine dayalı rasyonel tahminler yapar. GPR'nin çalışma prensibi, ortak olasılıksal yoğunluk fonksiyonlarına dayanmaktadır. Ortak bir, çok değişkenli olasılık yoğunluk fonksiyonu aracılığıyla mevcut bilgileri kullanarak sistem yanıtını inceler. Ardından, olasılık fonksiyonunu eş zamanlı olarak güncellerken gözlemleri kullanarak tahminlerde bulunur. Tahminler, eğitim veri noktaları ile test veri noktaları arasındaki mesafe karşılaştırılarak yapılır. Parametrik olmayan modeller, benzer çıktı değerlerine sahip veri noktalarının veri uzayında birbirine yakın olduğunu varsayar.

Gauss sürecinin matematiksel gösterimleri (3.30), (3.31), (3.32)'de verildiği gibidir. Denklemlerden de görüldüğü gibi Gauss süreci, kovaryans fonksiyonu $K(x, x')$ ve ortalama fonksiyon $\mu(x)$ ile tanımlanır. Bu eşitliklerde, $x, x' \in X$ rastgele değişkenlerdir.

$$f(x) \sim GP(\mu(x)K(x, x')) \quad (3.30)$$

$$\mu(x) = E[f(x)] \quad (3.31)$$

$$K(x, x') = E[(f(x) - \mu(x))(f(x') - \mu(x')))] \quad (3.32)$$

Gauss sürecini regresyon için kullanmanın diğer yöntemlere göre birçok avantajı vardır. GPR yönteminin çok fazla girdi özelliği gerektirmeden değişkenler arasındaki karmaşık ve tamamen doğrusal olmayan ilişkileri bulabilmesidir. Ayrıca, doğrusal regresyon yöntemlerinin yaptığı gibi açıkça tanımlanmış bir öğrenme modeli sunmak yerine, tahmin için tamamen kapalı formda çözüm adımları sağlar. Gauss süreç modelleri, eğitim verilerini kendi içinde saklar ve aralarındaki dağılım (interpolasyon) özelliklerini öğrenir. Sinir ağları gibi diğer parametrik makine öğrenimi yaklaşımları, eğitim verilerini saklamaz ve bu, doğrulamalarında zorluk yaratır. Gauss süreci (GP) modelleri, parametrik olmaması ve veri koruma özelliği nedeniyle tüm bileşenler için esnek bir modelleme yaklaşımına sahiptir.

3.5.5. Doğrusal Regresyon (Linear Regression)

Doğrusal regresyon [109, 122, 123], bağımsız değişken olan girdiler ile bunlara dayalı olarak hesaplanan çıktı arasındaki ilişkinin doğrusal olarak belirlendiği bir algoritmadır. Doğrusal regresyon, bir ya da daha fazla bağımsız değişken (X) ile bağımlı değişken (Y) arasında en uygun düz çizgiyi kullanarak bir ilişki kurar. Hata değeri minimuma indirgenmeye çalışılır. Doğrusal bir regresyon denklemindeki β değerleri, en küçük kareler yöntemi kullanılarak ε hatasının minimize edilmesiyle bulunur. Doğrusal regresyonda, Y bağımlı değişkeni, X bağımsız değişkeni, β_1 ve β_0 bu değişkenin bilinmeyen parametrelerini ve ε hata terimini ifade etmektedir. β_0 , fonksiyonun y eksenini kestiği noktayı, β_1 ise doğrunun eğimini temsil etmektedir. Lineer regresyon analizi, basit lineer regresyon ve çoklu lineer regresyon olarak incelenebilir. Basit doğrusal regresyon, bağımsız değişken

girdileri ile buna göre hesaplanan çıktı arasındaki ilişkinin doğrusal olarak belirlendiği bir algoritmadır. Basit doğrusal regresyon, (3.33) eşitliğinde verildiği gibi tanımlanabilir.

$$Y = \beta_0 + \beta_1 X_{1i} + \varepsilon_i \quad i = 1, 2, \dots, n \quad (3.33)$$


Çoklu doğrusal regresyonda, tek bir bağımlı değişken ve birden fazla bağımsız değişken vardır ve bunların arasındaki doğrusal ilişki ifade edilmektedir. (3.34) eşitliğinde, $X_1, X_2, \dots, X_n$ çoklu değişkenleri, Y bağımlı değişkeni, $\beta_0, \beta_1, \dots, \beta_p$ bilinmeyen parametreleri ve ε hatayı ifade etmektedir. Çoklu doğrusal regresyon modeli, p adet bağımsız değişken ve n adet gözlem için (3.34) denkleminde verildiği gibidir.

$$Y = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_p X_{pi} + \varepsilon_i \quad i = 1, 2, \dots, n \quad (3.34)$$


4. DERİN ÖĞRENME AĞLARI

Derin Öğrenme [12, 124, 125], yapay sinir ağları adı verilen beynin yapısından ve fonksiyonundan esinlenerek oluşturulan algoritmalarla ilgili olarak yapay zekadaki makine öğrenimi algoritmasının sınıfıdır. Yapay sinir ağları (YSA) ve bunlara dayalı yapay sinir ağı tasarımları, birbirine bağlı bilgisayar birimlerinden oluşan ağlar derin öğrenme algoritmalarının fiziksel temelini oluşturmaktadır.

Yapay sinir ağları [126, 127, 128], biyolojik beynin nöronlarına benzeyen yapay nöronlar olarak bilinen birbirine bağlı birimlerden veya düğümlerden oluşan bir ağıdır. Yapay sinir ağları, genellikle bir giriş katmanı, gizli katman(lar) ve bir çıktı katmanı içeren çok katmanlı bir yapıya sahiptir (Şekil 4.1). İnsan beynindeki sinapslara benzer şekilde, her bağlantı iki nöron arasındaki iletişimi sağlar. Her yapay nöron, bir sonraki yapay nöron katmanı tarafından kullanılabilen girdiler ve çıktılar içerir. Girişler, veri örneğinin özellikleri veya önceki katmanda bulunan diğer nöronların çıktıları olabilir. Son katmandaki nöronların çıktıları sistemin çıktılarıdır. Bir nöronun çıktısını hesaplamak için tüm girdilerin ağırlıklı toplamı, nöron bağlantılarıyla ağırlıklandırılmış, doğrusal olmayan bir aktivasyon fonksiyonundan geçirilir (Şekil 4.2). Öğrenme sürecinde sonucun daha doğru olması ve hata fonksiyonunun en aza indirgenmesi için geri yayılım algoritmasıyla ağırlıklar değiştirilir.



Şekil 4.1. Yapay Sinir Ağı [129].



Şekil 4.2. Yapay bir nöronun şematik gösterimi [128].

Derin öğrenme, verileri işlerken ve karar vermede kullanılmak üzere modeller oluştururken insan beynini taklit eder. Temelde üç veya daha fazla katmana sahip bir sinir ağından oluşur. Buna göre, derin öğrenme mimarisi çok katmanlıdır. Ek gizli katmanlara sahip sinir ağları, yaklaşık tahminler yapabilen bir katmanlı sinir ağlarına kıyasla daha doğru sonuçlar üretir. DL, üzerinde çalışabilmesi için büyük miktarda veriye ihtiyaç duyar ve ayrıca karmaşık yapısı nedeniyle bu verileri işleyebilmek için çok güçlü donanımlara ihtiyaç duyar.

Derin öğrenme ağlarının önemli katkılarından biri, geleneksel tam bağlantılı yapay sinir ağlarındaki parametre sayısını azaltmasıdır. Belirli bir durum için doğru öznitelikleri seçmek genellikle zor bir konudur. Derin öğrenme algoritmaları, önceden seçilmiş öznitelik yerine ham girdi verilerinden ilgili öznitelikleri çıkararak öznitelik seçimi problemini otomatik olarak çözmektedir. Bir DL algoritması, farklı soyutlama derecelerinde çeşitli veri özelliklerini öğrenebilen çok sayıda işleme katmanından oluşmaktadır. Böylece ağ farklı seviyelerde farklı öznitelikler öğrenebilmektedir.


4.1 Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNNs)

RNN [12, 130-135], önceki durumun çıktısının mevcut duruma girdi olarak kullanıldığı bir sıralı sinir ağı türüdür. Giriş serisini sırayla işlemek için ayarlanmıştır. Bu yapının çekirdek birimleri, kendi çıktı değerleriyle kendilerini beslemeleriyle tanınırlar. Buna göre çıktı değeri üreten işlemin hemen ardından bu birimin bir önceki girdiden herhangi bir bilgi öğrenip öğrenmediğini test ederken bu değeri de kendisi için girdi olarak

geri gönderir. Bu birimleri art arda bir araya getirmek, RNN ağlarının oluşturulmasına izin verir.


RNN, dahili belleğe sahip ileri beslemeli sinir ağının genelleştirilmiş halidir. RNN, doğası gereği tekrarlayıcıdır. Çıkış üretildikten sonra kopyalanır ve tekrarlayan ağa geri gönderilir. Karar verirken mevcut girdiyi ve bir önceki girdiden öğrendiği çıktıyı dikkate alır.

Geleneksel yapay sinir ağı yapıları, bir örnek içindeki özelliklerin birbirinden bağımsız olduğunu varsayar. Yalnızca girişlerden çıkışlara eşlenirler ve döngüsel bağlantıları yoktur. İleri beslemeli sinir ağlarının aksine, RNN'ler giriş dizilerini işlemek için dahili durumlarını (belleklerini) kullanabilirler. RNN'ler önceki tüm girişlerden çıkışlara eşlenirler ve döngüsel bağlantıları vardır, yani RNN'ler dizi verilerini modellemede iyi olan sinir ağlarıdır ve tüm girişler birbiriyle ilişkilidir. RNN'ler, Şekil 4.1'den de görüldüğü gibi sinir ağına önceki bilgileri iletebilen bir döngü eklenerek oluşturulmuştur.




Şekil 4.3. Tekrarlayan sinir ağı şeması [136].

Şekil 4.3'teki RNN yapısı incelendiğinde, A birimi sinir ağı modelidir ve t zamanında x_t girişine karşılık h_t çıkışı üretilmektedir. RNN'lerde kullanılan döngü yapısı ile üretilen h_t çıkışı $t+1$ zamanında giriş olarak kullanılabilir. Birden fazla sinir ağı zaman içerisinde tekrarlanarak RNN modeli elde edilmektedir. Her bir birimde, o andaki veri işlenmekte ve elde edilen çıktı ise bir sonraki adıma iletilmektedir.



Şekil 4.4. Zaman adımları içerisinde tekrarlanan RNN modeli [136].

Şekil 4.4 göz önüne alındığında, genel ağ girişleri bir dizi olarak almaktadır. Buna göre tekrarlayan birim (gizli katman) hem çıktı hem de geçmiş değeri oluşturmaktadır. Daha sonra oluşturulan geçmiş değeri, bir sonraki girişle birlikte aynı tekrarlayan birime verilir. Genel mekanizma, bir dizideki son girdi işlenene kadar bu şekilde devam eder.



Şekil 4.5. RNN’de mevcut durumun girişi ile önceki durumun çıkışının birlikte kullanılması [136].

Şekil 4.5 incelendiğinde, RNN şu şekilde çalışır: Girişler, makine tarafından okunabilen vektörlere dönüştürülür. Daha sonra RNN, vektör dizisini birer birer işler. İşleme sırasında önceki gizli durumdan dizinin bir sonraki adımına geçer. Gizli durum, sinir ağlarının belleği gibi davranır. Ağın daha önce gördüğü önceki veriler hakkında bilgi tutar. Gizli durumun nasıl hesaplanacağını görmek için bir RNN hücresi incelenirse ilk olarak, giriş ve önceki gizli durum bir vektör oluşturmak için birleştirilir. Bu vektör artık mevcut giriş ve önceki girişler hakkında bilgiye sahiptir. Vektör, tanh aktivasyonundan geçer ve çıktı, yeni gizli durum veya ağın hafızasıdır.

$$h_t = \tanh(w_{hh}h_{t-1} + W_{xh}x_t + b_h) \quad (4.1)$$

$$y_t = \tan_y(W_{hy}h_t + b_y) \quad (4.2)$$

Burada w ağırlık matrisidir, whh önceki gizli durumdan hesaplanan ağırlık matrisidir, h gizli katman vektörü, wxh mevcut durum için ağırlık bilgisini temsil etmektedir, $\tan_h$ ve $\tan_y$ genel çıkış değerinin -1 ile 1 arasında olmasını sağlayan aktivasyon fonksiyonlarıdır. RNN, adımında her zaman bir önceki adımın gizli çıktısını kullanır. Böylece zaman adımları arasında bağlantı kurabilir.

4.2 Uzun Kısa-Süreli Bellek (Long Short-Term Memory, LSTM) Ağları

LSTM [12, 136-144], geri yayılma kullanılarak eğitilmiş RNN'lerin daha gelişmiş bir çeşididir ve standart RNN'de yaygın olan sorunlardan kaçınmak için tasarlanmış bir tekniktir.

İlk ve son girdi arasındaki boşluk büyüdükçe uzun ardışık veriler için bilgileri bağlamakta zorluk yaşayan RNN'ler geçmişte gördükleri bilgileri unutmaya başlar ve bilgileri ilişkilendirmeyi öğrenemez hale gelir. RNN'lerdeki kısa süreli bellek, kaybolan gradyan probleminden kaynaklanmaktadır. Kısa süreli bellek ve kaybolan gradyan, sinir ağlarını eğitmek ve optimize etmek için kullanılan bir algoritma olan geri yayılımın doğasından kaynaklanmaktadır.

Bir sinir ağını eğilirken öncelikle, bir ileri yayılım yapılır ve bir tahminde bulunulur. İkincisi, bir kayıp fonksiyonu kullanılarak tahmin temel gerçeğe karşılaştırılır. Kayıp fonksiyonu, ağı ne kadar kötü performans gösterdiği ile ilgili bir hata değeri verir. Son olarak, ağıdaki her düğüm için gradyanları hesaplayan geri yayılımı yapmak için bu hata değeri kullanılır.

Gradyanlar, bir sinir ağı ağırlıklarını güncellemek için kullanılan değerlerdir. Eğitim ne kadar büyük olursa, ayarlamalar da o kadar büyük olur ve bunun tersi de geçerlidir. Sorunun yattığı yer burasıdır. Geri yayılımı yaparken, bir katmandaki her bir düğüm kendi gradyanını kendisinden önceki katmandaki gradyanların etkilerine göre hesaplar. Dolayısıyla, kendisinden önceki katmanlardaki ayarlamalar küçükse, mevcut katmandaki ayarlamalar daha da küçük olacaktır.

Bu, aşağı doğru yayıldığı için gradyanların katlanarak küçülmesine neden olur. İç ağırlıklar son derece küçük gradyanlar nedeniyle zor ayarlandığı için, önceki katmanlar herhangi bir öğrenme gerçekleştiremez. Ve bu, kaybolan gradyan problemidir. Kaybolan

gradyan probleminde gradyan zaman içinde geri yayılırken küçülür ve bir gradyan değeri aşırı derecede küçük olursa, öğrenmeye çok fazla katkı sağlamaz.

Bu durum, tekrarlayan sinir ağları için de geçerlidir. RNN'lerdeki her zaman adımı bir katman olarak düşünülebilir. Gradyan değerleri, her zaman adımında yayıldıkça katlanarak küçülecektir.


Yine gradyan, sinir ağlarının ağırlıklarında ayarlamalar yapmak için kullanılır ve böylece öğrenmesini sağlar. Küçük gradyanlar, küçük ayarlamalar anlamına gelir. Dolayısıyla tekrarlayan sinir ağlarında, küçük bir gradyan güncellemesi alan katmanlar öğrenmeyi durdurur. Bunlar genellikle önceki katmanlardır. Dolayısıyla bu katmanlar öğrenmediği için, RNN'ler daha uzun dizilerde gördüklerini unutabilir ve böylece kısa süreli bir belleğe sahip olabilir, zaman adımlarında uzun vadeli bağımlılıkları öğrenmez.

LSTM ağları, öğeler arasındaki ilişkileri öğrenirken uzun vadeli bağımlılıkları hatırlama yeteneğine sahip, tekrarlayan sinir ağı yapılarının özel bir versiyonudur. Bu ağlar, uzun diziler boyunca bilgi taşıırken dayanıklı olmalarıyla da bilinirler, tekrarlayan bir sinir ağı ile benzer bir kontrol akışına sahiptir. İleriye doğru yayılırken bilgi aktaran verileri işler. Farklılıklar, LSTM'nin hücreleri içindeki işlemleridir. Bu işlemler, LSTM'nin bilgileri tutmasına veya unutmaya izin vermek için kullanılır. LSTM yapıları, LSTM'nin ardışık katmanlar aracılığıyla bilgi iletmesine izin veren hücre durumları tarafından desteklenir. LSTM'nin iç yapısı, hücre durumları üzerinde belirli işlemleri gerçekleştiren giriş kapısı, çıkış kapısı ve unutma kapısı olmak üzere üç ana bölümden oluşur. Unutma kapısı olan ilk alt modül, hücre durumundaki ilgisiz verilerden basitçe kurtulur. Öte yandan, hücre durumuna yeni bilgi ekleme görevi için bir giriş kapısı atanır. Son olarak, genel yapıdan yararlı bilgilerin seçilmesi ve çıktı verileri olarak gösterilmesi, çıkış kapısı tarafından tamamlanır.

i_t giriş kapısı, f_t unutma kapısı, c_t , o_t ve h_t , t zamanında sırasıyla hücre aktivasyon vektörleri, çıkış kapısı ve gizli vektördür. x_t , sistemin t zamanındaki girişini temsil eder, σ ve $\odot$ sırasıyla lojistik sigmoid fonksiyonu ve eleman bazında çarpmadır. Şekil 4.6'da LSTM yapısı gösterilmektedir.

Bir tanh fonksiyonu, değerlerin -1 ile 1 arasında kalmasını sağlayarak sinir ağının çıkışını düzenler. Kapılar, sigmoid aktivasyonları içermektedir. Bir sigmoid aktivasyonu ise tanh aktivasyonuna benzer, değerlerin -1 ile 1 arasında olmasını sağlamak yerine, 0 ile 1 arasında olmasını sağlar. Bu, verileri güncellenmesinde veya unutulmasında kullanılır çünkü 0 ile çarpılan herhangi bir sayı 0'dır, bu da değerlerin kaybolmasına veya unutulmasına neden olur. 1 ile çarpılan herhangi bir sayı aynı değerdir, dolayısıyla bu değer aynı kalır veya

tutulur. Ağ, hangi verilerin önemli olmadığını öğrenebilir, bu nedenle unutulabilir veya hangi verilerin tutulmasının önemli olduğunu öğrenebilir.



Şekil 4.6. LSTM birimi içerisindeki bileşenler [138].

LSTM ağlarında, hücre durumu tahminlerde bulunmak için hücreler arasında anlamlı bilgiler taşıyan bir iletişim hattıdır. Ağın belleği olarak açıklanabilir. Bu nedenle, daha önceki zaman adımlarından gelen bilgiler bile daha sonraki zaman adımlarına geçerek kısa süreli belleğin etkilerini azaltabilir. Hücre durumunun taşınması gereken bilgiler kapılar aracılığıyla belirlenir. Hücre durumu yolculuğuna devam ederken, kapılar aracılığıyla hücre durumuna bilgi eklenir veya çıkarılır. Kapılar, hücre durumunda hangi bilgilere izin verildiğine karar veren farklı sinir ağlarıdır ve eğitim sırasında hangi bilgilerin gerekli veya gereksiz olduğunu, hangi bilgilerin saklanması veya unutulması gerektiğini öğrenebilirler.

a) Unutma Kapısı: Unutma kapısı, hangi bilgilerin unutulacağına veya saklanacağına karar veren kapıdır. Bir önceki hücreden (h_{t-1}) gelen bilgi ve mevcut bilgi (x_t) sigmoid aktivasyon fonksiyonuna girilir ve sonuca göre karar verilir. 0 ile bilgi unutulur ve 1 ile bilgi hücre durumu ile taşınmaya devam eder. (4.3) eşitliğinde verildiği gibi ifade edilebilir.

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (4.3)$$

b) Giriş Kapısı: Giriş kapısı hücre durumunu günceller. İlk olarak, önceki gizli durum (h_{t-1}) ve mevcut giriş (x_t) bir sigmoid fonksiyonundan geçirilir. (4.4) eşitliği ile ifade edilen (i_t) elde edilir. Sigmoid işleminin sonucuna göre önceki ve güncel bilgilerin güncellenip güncellenmeyeceğine karar verilir. 0 ile verilen bilgiler önemsiz, 1 ile verilen bilgiler önemli olarak kabul edilir. Ayrıca, ağı düzenlemeye yardımcı olmak için bilgilerin -1 ile 1

arasındaki değerlerde olmasını sağlamak için önceki gizli durum (h_{t-1}) ve mevcut giriş (x_t), tanh fonksiyonuna iletilir, ($\bar{c}_t$) elde edilir (Şekil 4.4). Daha sonra, tanh çıktısı sigmoid çıktısıyla çarpılır. Sigmoid çıktısı, tanh çıktısından hangi bilginin saklanması gerektiğine karar verecektir.

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (4.4)$$

c) Hücre Durumu: Öncelikle, hücre durumu (c_{t-1}) unutma vektörü (f_t) ile noktasal olarak çarpılır. Bu, 0'a yakın değerlerle çarpılırsa hücre durumundaki değerleri düşürme olasılığına sahiptir. Ardından, giriş kapısından çıktı alınır ve hücre durumunu sinir ağının ilgili bulduğu yeni değerlere güncelleyen noktasal bir ekleme yapılır. Bu, yeni hücre durumunu (c_t) verir. (4.5) eşitliğinde yeni hücre durumunun formülasyonu gösterilmektedir.

$$c_t = f_{t\odot}c_{t-1} + i_{t\odot}\tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (4.5)$$

d) Çıkış Kapısı: Çıkış kapısı, bir sonraki gizli durumun ne olması gerektiğine karar verir. Gizli durum, önceki girişler hakkında bilgi içermektedir ve tahminler için de kullanılır. İlk olarak, önceki gizli durum (h_{t-1}) ve mevcut giriş (x_t) sigmoid fonksiyonundan geçirilir, (4.6) eşitliği ile ifade edilen (o_t) elde edilir. Daha sonra, yeni değiştirilen hücre durumu (c_t), tanh fonksiyonuna aktarılır. Gizli durumun hangi bilgileri taşıması gerektiğine karar vermek için tanh çıkışı sigmoid çıkışıyla (o_t) çarpılır. Çıkış, gizli durumdur (h_t). Sonrasında, yeni hücre durumu (c_t) ve yeni gizli durum (h_t) bir sonraki zaman adımına taşınır.

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_{t-1} + b_o) \quad (4.6)$$

$$h_t = o_{t\odot}\tanh(c_t) \quad (4.7)$$

Özetlemek gerekirse, unutma kapısı önceki adımlardan neyin saklanması gerektiğine karar verir. Giriş kapısı, geçerli adımdan hangi bilgilerin ekleneceğine karar verir. Çıkış kapısı ise bir sonraki gizli durumun ne olması gerektiğini belirler.


4.3 Evrişimli Sinir Ağları (Convolutional Neural Networks, CNNs)

CNN'ler [12, 27, 145, 146] temel olarak yapay sistemlerde, görüntü tanıma, görüntü sınıflandırmaları yapmak, benzerlikleri kümelemek için kullanılan derin sinir ağlarıdır. Nesne algılama, yüz tanıma, video sinyal işleme vb. CNN'lerin yaygın olarak kullanıldığı alanlardan bazılarıdır.

Evrişimsel sinir ağı, ağırlıklı olarak görüntü tanıma ve sınıflandırmada olduğu gibi ızgara benzeri topolojiye sahip verilerin işlenmesinde kullanılan bir yapay sinir ağı türüdür. Diğer görüntü sınıflandırma algoritmalarıyla karşılaştırıldığında, CNN'lerin ana avantajı, denetimsiz bir öğrenme biçimi olması ve verilerden öznitelikleri öğrenmek için etiketli örnekler gerektirmemesidir. Görüntüler ve zaman serisi verileri gibi çeşitli eğitim verileri kümesinden öznitelikleri verimli bir şekilde işleme ve öğrenme konusunda güçlü yetenekleri vardır. CNN ile manuel öznitelik çıkarma ihtiyacı ortadan kalkmıştır ve öznitelikler doğrudan CNN tarafından öğrenilmektedir [147, 148]. Bu avantajı nedeniyle, CNN en yaygın kullanılan derin öğrenme ağlarından biri haline gelmiştir. CNN'ler ileri beslemeli bir mekanizmaya dayalı olarak tasarlanmış derin öğrenme ağlarıdır. CNN'de güncellenmesi gereken parametrelerin sayısının azaltılmasıyla ezberleme olmadan eğitim kolaylığı nedeniyle de tercih edilmektedir [149].

CNN'ler, geleneksel yapay sinir ağları (*Artificial Neural Networks, ANN*) ile karşılaştırıldığında ANN'lerde, her giriş nöronu bir sonraki katmandaki çıkış nöronlarına bağlıdır ve buna tam bağlantılı katman yapısı denir. Bununla birlikte, CNN'lerde, öznitelikleri çıkarmak için evrişim katmanları, her evrişim katmanında farklı filtreler kullanır. Daha sonra havuzlama katmanları kullanılarak sonuçlar birleştirilir, genel olarak, havuzlama katmanları evrişim katmanlarını takip eder. Havuzlama, önemli göze çarpan öznitelikleri korurken, öznitelikler haritasının boyutunu azaltır. Her filtrenin belirli öznitelikleri tanımladığı düşünülebilir. Tam bağlantılı katman, önceki katmanlarda çıkarılan özniteliklere dayalı olarak girdi verilerini sınıflandırmak veya tahminlerde bulunmak için kullanılır. Eğitim aşaması boyunca bir CNN, yapacağı göreve göre filtreleriyle ilgili değerleri otomatik olarak öğrenecektir. Örneğin, görüntü sınıflandırması için kullanıldığında, bir CNN birinci katmandaki ham piksellerden kenarları algılamayı öğrenir. Bundan sonra, ikinci katmandaki basit şekilleri algılamak için kenarlar kullanılır ve ardından şekiller, en üst katmanlardaki yüz şekilleri gibi üst düzey özellikleri algılamak için kullanılır. Son katman, üst düzey özellikleri uygulayan bir sınıflandırıcıdır [150]. Şekil 4.7'de klasik bir CNN modelinin katmanlarının şeması gösterilmektedir.

CNN, çok boyutlu verilerde olduğu gibi 1 boyutlu sensör verilerinin sınıflandırılması ve regresyonu için de kullanılmakta ve doğru tanıma sonuçları üretmektedir. Birçok gizli katmana ve parametreye sahip çok boyutlu CNN'ler, çok büyük boyutlu bir görsel veri tabanı üzerinde eğitilebilmeleri koşuluyla, karmaşık nesneleri ve örüntüleri öğrenebilme yeteneğine sahiptirler. Fakat bu, özellikle eğitim verileri az olduğunda veya uygulamaya özel olduğunda, 1 boyutlu sinyaller üzerinden çok sayıda uygulamada geçerli bir seçenek olmayabilir. 1 boyutlu evrişimler, skaler çarpmalar ve toplamalar gerçekleştiren 1-B CNN'lerin basit ve kompakt yapılandırması nedeniyle gerçek zamanlı ve düşük maliyetli donanım uygulamalarını mümkün kılmaktadır [151-153].



Şekil 4.7. Klasik bir CNN modeli katmanları [155].


CNN'ler, ileri beslemeli sinir ağı yapısı üzerine inşa edilen bir yapı türüdür. CNN'deki katmanlar, öznetelik öğrenme alt ağı ve sınıflandırma alt ağı olmak üzere iki ana kategoriye ayrılabilir. Sınıflandırma göz önüne alındığında, öznetelik öğrenme alt ağı, giriş katmanı, evrişim katmanı ve havuzlama katmanı olmak üzere üç farklı katmana ayrılabilirken, sınıflandırma katmanı tam bağlantılı katman, soft-max katmanı ve çıkış katmanı olarak ayrılabilir. Tüm bu alt ağlar, belirli görevleri yerine getirirler. Giriş katmanı, giriş verilerinin genel ağı verildiği katmandır. CNN'de verilerin bilgisayarlar tarafından işlenebilir bir formata getirilmesi gerektiği için görüntü ya da zaman serisi verileri matris formatında alınır. Çıkış katmanı ise elde edilen sonuçlara karşılık gelen etiketlere eşlenmektedir. Bunların dışında evrişimsel sinir ağlarının sahip olduğu katmanlar şunlardır:

a) Evrişim Katmanı (Convolutional Layer): Evrişim katmanı [127, 134, 155, 156, 157], verilerin özneteliklerini saptamak için kullanılır ve hesaplamaların çoğu bu katmanda

gerçekleştirilir. CNN algoritmalarında giriş verisini işleyen ilk katmandır. Giriş matrisleri, belirli değerlere sahip piksellerden oluşan matrislerdir. Bu katman, girişteki düşük ve yüksek seviyeli öznitelikleri çıkarmak için girişe bazı filtreler uygular. Evrişim katmanında, orijinal giriş verisinin boyutundan daha küçük bir filtre matrisi üzerinde hareket ettirilerek ve bununla birlikte basit matris çarpımı yapılarak bu matrislerden belirli öznitelikleri yakalamaya çalışır. Filtreden geçirilme sonucu oluşan değerler öznitelik matrisini oluşturur. Birden fazla özniteliğin tespit edilmesi için birden fazla filtre kullanılmaktadır. Evrişimsel sinir ağında, birden fazla evrişim katmanı bulunmaktadır. Örnek bir evrişim katmanı Şekil 4.8’de gösterilmiştir. CNN algoritmalarında öğrenilen parametreler bu filtrelerdeki değerlerdir. Model bu değerleri sürekli günceller ve öznitelikleri daha iyi algılamaya başlar.

Çok boyutlu filtreler, piksel değerlerinden oluşmaktadır. Örneğin (4x4x2) filtresinde, 4 matrisin yüksekliğini ve genişliğini, 2 matrisin derinliğini temsil etmektedir.

Şekil 4.8’de verilen örnekte, giriş matrisinin 4x4 boyutunda olduğu varsayılırsa ve filtre matrisi 2x2 boyutunda oluşturulursa basit matris çarpımları yapılarak 3x3 boyutunda öznitelik matrisi elde edilir.



Şekil 4.8. Evrişim katmanında filtrenin uygulanışı [129].

Evrişim katmanı işlemi, (4.8) eşitliğindeki gibi matematiksel olarak ifade edilebilir.

$$(f * g)[n] = \sum_{m=-\infty}^{\infty} f[m]g[n - m] \quad (4.8)$$

Burada, $f[m]$ girişı, $g[n - m]$ ise girişteki çekirdek evrişimini ifade etmektedir [158].


Giriş matrisi genellikle filtre matrisinden daha büyüktür. Çekirdek, veri seti üzerinde sadece bir alanı tarayabildiği ve veri seti dışına çıkamadığı için veri setinin sınırındaki veri noktası, veri setinin merkezindekiler gibi doğru bir şekilde öğrenilememektedir. Filtre boyutu giriş matrisiyle eşleşmiyorsa dolgu (*padding*) kullanılır. Sıfır dolgusu ile giriş matrisinin etrafı sıfırlarla doldurulur ve böylece giriş matrisinin sınırlarında kaybolan veriler öznitelik haritasına dahil edilmiş olur. Diğer bir yöntem ise giriş matrisinin yalnızca geçerli kısımlarını tutan geçerli dolgu kullanmaktır. Giriş matrisinde filtrenin uymadığı kısım bırakılır. Sıfır dolgu eklemek geniş evrişimdir, sıfır dolgu eklememek dar evrişimdir.

Adım (stride), filtrenin giriş matrisi üzerinde hareket ettiği mesafe veya piksel sayısıdır. Adım 1 olduğunda, filtreler her seferinde 1 piksel taşınır. Adım 2 olduğunda, filtreler her seferinde 2 piksel taşınır ve adım sayısına göre kaydırma işlemi yapılır. Şekil 4.6'da verilen örnekte stride=1 olarak alınmıştır.

Elde edilen verilerin doğrusal olmamasından dolayı veriler aktivasyon fonksiyonundan geçirilir. Her evrişim katmanından sonra öznitelik matrisine bir aktivasyon fonksiyonu uygulanarak ağı doğrusal olmama durumu eklenir. Her nöronun çıkışı, aktivasyon fonksiyonları tarafından 1 ile 0 (veya -1 ile 1) arasında bir aralığa normalleştirilir. Çeşitli aktivasyon fonksiyonları vardır, çalışmamızda sinir ağı eğitiminin hızı konusunda en iyi sonucu Doğrultulmuş Lineer Ünite (*Rectifier Linear Unit, ReLu*) fonksiyonu verdiği için bu fonksiyon kullanılmıştır. Ayrıca diğer aktivasyon fonksiyonlarına göre daha hızlı sonuç üretmektedir. Şekil 4.9'da aktivasyon fonksiyonlarının grafikleri ve formülasyonları gösterilmektedir.

ReLu fonksiyonunda, gelen girişler sıfır ile sonsuz arasındaki çıkışlara dönüştürülür. Bu fonksiyonun diğer aktivasyon fonksiyonlarına göre avantajı, tüm nöronları aynı anda aktive etmemesi, çok hızlı hesaplanabilmesi ve kaybolan gradyan sorununa karşı dayanıklı olmasıdır.


ReLU fonksiyonunda, tüm negatif girdiler sıfıra çevrilmekte ve nöron aktifleşmemektedir. Her seferinde birkaç nöron etkinleştirildiği için hesaplama açısından çok verimli hale getirir. ReLU fonksiyonu, tanh ve sigmoid aktivasyon fonksiyonlarından altı kat daha hızlı yakınsar.



Şekil 4.9. Aktivasyon Fonksiyonları [148].


b) Havuzlama Katmanı (Pooling Layer): Konvolüsyon katmanının evrişim işleminden sonra verilerin öznitelikleri çıkarılmaktadır ancak çıkarılan öznitelik boyutları çok yüksektir, bu nedenle bu sorunu çözmek, daha az parametre uygulayarak ağı eğitimi süresini azaltmak ve öznitelik boyutunu azaltmak için evrişimden sonra bir havuzlama katmanı eklenir. Havuzlama katmanı [127, 134, 148], elde edilen matrisi daha düşük bir vektör uzayında temsil ederek devreye girer, verilen giriş için ölçek küçültme işlemi gerçekleştirir. Ezberlemeyi kontrol etmeye de yardımcı olur. Çoğu durumda, havuzlama katmanı iki evrişim katmanı arasında konumlandırılır. Bu katman ile evrişimsel sinir ağının öznitelik çıkarım kısmı görevini yerine getirmiş ve elde edilen veriler bir sonraki sınıflandırma görevinden sorumlu kısım için hazır hale gelmiş olur.

Bağımsız fonksiyonlar, öznitelik matrislerinin her biri üzerinde havuzlama katmanı tarafından uygulanır. Şekil 4.10'da görülebileceği gibi, maksimum havuzlama, filtrenin kapsadığı alandaki en büyük değeri alır ve öznitelik matrisin en belirgin özelliklerini korur. Ortalama havuzlama, filtredeki değerlerin ortalamasını alır ve öznitelik matrisinin ortalama değerlerini korur. Minimum havuzlama ise filtrenin kapsadığı alandaki en küçük değeri alır. Bu katmanlar, boyutu ve işlem gücünü azaltır ve temel özellikleri korur.



Şekil 4.10. Havuzlama Yöntemleri [148].

c) Düzleştirme Katmanı (Flattening Layer): Tam bağlantılı katman için verileri hazırlar. Bu katmanın görevi, son katman olan tam bağlantılı katmanın girişindeki verileri hazırlamaktır. Sinir ağları, genelde giriş sinyallerini tek boyutlu sütun vektöründen almaktadırlar. Bu sinir ağındaki veriler, evrişimli katman ve havuzlama katmanından gelen verilerin tek boyutlu matrise çevrilmiş halidir.




Şekil 4.11. Düzleştirme İşlemi [159].

d) Tam Bağlantılı Katman (Fully Connected Layer): Tam bağlantılı katman [129, 160, 161] sınıflandırma işleminde kullanılan standart sinir ağıdır. Düzleştirme katmanından verileri alır ve bu veriler üzerinden geleneksel sinir ağı işlemlerini gerçekleştirirken, ileri besleme ve geri yayılım faaliyetleri gerçekleştirerek yapay nöronlar arasındaki ağırlıkları ve sapmaları hesaplar ve ayarlar. Girdiyi ağırlık matrisi ile çarpar ve ardından bir sapma vektörü ekler. Önceki katmandaki tüm nöronlar, tam bağlantılı katmandaki nöronlara bağlıdır. Sınıflandırma görevleri için, son tam bağlantılı katman, önceki katmanlardan çıkarılan özniteliklere dayalı olarak sınıflandırma gerçekleştirir ve tam bağlantılı katmanın çıktı boyutu, veri setinin sınıf sayısına eşittir. Regresyon görevleri için, son tam bağlantılı katmanın çıktı boyutu, yanıt değişkenlerinin sayısına eşit olmalıdır. Tam bağlantılı katmanlar, CNN mimarisinin sonunda bulunur. Girişleri düzgün bir şekilde sınıflandırmak için softmax aktivasyon fonksiyonu genellikle son tam bağlantılı katmana uygulanır. Softmax yönteminde [157], sınıf sayısı kadar düğüm oluşturulur ve sınıflandırma işlemi içerisinde oluşturulan düğümlerin bir sınıfa ait olmaları ile ilgili (0-1) aralığında olasılık değerleri üretilir.

Tam bağlantılı katmanların sayısı, öğrenme derinliğini artırmanın yanı sıra hesaplanacak parametre sayısını da artırır. Gizli katman sayısının belirlenmesi, CNN mimarisinde kritik bir görevdir. Düşük katman sayısı, karmaşık örüntülerin öğrenilmesine izin vermez. Çok sayıda katman, öğrenmeden çok ezberlemeye yol açabilir. Bu da eğitim süresini artırmaktadır. Gizli katman sayısı, ağı performansı için belirleyicidir. Sezgisel olarak katman sayısının giriş ve çıkış katmanlarının sayısı ve eğitim parametrelerinin sayısı ile ilişkili olduğu söylenebilir.

Derin sinir ağlarında, iki ardışık tam bağlantılı katman arasında ezberlemenin engellenmesi için seyreltme katmanı (*dropout layer*) ve aktivasyon fonksiyonu kullanılır. Seyreltme katmanı, belirli eşlemeleri öğrenmemek için bağlantılarının seçilebilir bir yüzdesini rastgele bırakır ve öğrenilen ağırlıklara fazlalıklar uygular. Zayıf bilgilere sahip olan düğümler bırakılarak hata optimizasyonuna katılması engellenir. Böylece, ezberlemenin önüne geçilir ve ağı dahil edilmeyen nöronlar hesaplanan toplam hatanın geriye yayılımı sırasında da sürece dahil edilmezler.




Şekil 4.12. Tam Bağlantılı Katman

4.3.1 Zamansal Evrişimli Ağlar (Temporal Convolutional Neural Networks, TCNs)


TCN [162-164], dizileri işlemek için CNN üzerine inşa edilmiş bir mimaridir. Standart CNN, çoğunlukla görsel verileri işlemek için kullanılır ve diziler üzerinde çalışmaz. TCN, zaman serisi içeren öğrenme görevlerinde yüksek başarı elde etmektedir. Aynı uzunlukta bir çıktı üretmek için herhangi bir uzunlukta bir girdi dizisi alabilen bir mimaridir. Çalışmada, LSTM ağının tam bağlantılı katmanının çıkışı, TCN'nin girişine bağlanmıştır.

Ağın alıcı alan boyutu, $R = (f - 1) (2^K - 1) + 1$ olarak ifade edilebilir. Bu ifadede K, evrişim katmanlarının sayısıdır, f filtre boyutudur, adım 1'dir ve $(2^K - 1)$, k'inci evrişim katmanının genişleme faktörüdür. TCN mimarisi şekil 4.13'te gösterilmektedir ve çalışmada kullanılan TCN bloğu şekil 4.14'te gösterildiği gibidir. TCN'nin iki dizi genişletilmiş nedensel evrişim katmanı vardır ve bunlar aynı genişleme faktörüne sahiptir. Daha sonra evrişimsel filtreler normalizasyon uygulanmıştır, arkasından aktivasyon fonksiyonu olarak ReLU uygulanmıştır. Düzenleştirme için ise ReLU'nun arkasından bir uzamsal seyreltme uygulanmıştır. Girdi ve çıktı boyutları aynı olmadığında 1x1 evrişim eklenmiştir [163]. 1 genişleme faktörü ile başlayarak, her biri bir önceki katmanın iki katı genişleme faktörüne sahip olan bu bloklardan dördünü seri halinde içeren bir ağ tanımlanmıştır.



Şekil 4.13. TCN Mimarisi

TCN’de nedensel evrişim vardır. Nedensel evrişimler, gelecekteki verilerin sonuçları etkilemesini engellediği için yalnızca geçmiş ve güncel bilgileri kullanarak dizi sınıflandırmasına izin verir. TCN ayrıca verilere daha geriden itibaren bakabilmek için genişletilmiş evrişimler kullanır. Yalnızca nedensel evrişimler kullanıldığında, TCN ağ derinliğine doğrusal derinlikte bir geçmişe bakabilir. Genişletilmiş evrişimler, ağın geçmişi ağ derinliğine göre üstel derinlikte tutmasına izin verir [165, 166]. Nesne tanıma alanında kullanılan evrişimli katmanlar iki boyutluyken, dizi modelleme alanında tek boyutlu evrişimli sinir ağları (1D CNN) kullanılmaktadır [12].



Şekil 4.14. TCN Bloğu

5. TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR

5.1 Kullanılan Veri Tabanı

Bu çalışmada [167]'de verilen veri seti kullanılmıştır. İnsan beyni, tüm uçucu kimyasal bileşikleri ayrı ayrı sınıflandırmadan koku olarak algılar. Bu nedenle e-burun sistemlerinde kullanılan sensörlerin de çok çeşitli kimyasallara karşı hassasiyet göstermesi beklenmektedir. Farklı bir sıcaklıkta çalışan bir metal oksit (*Metal Oxide, MOX*) gaz sensörü farklı davranır. Bu nedenle, sensör verileri, farklı sıcaklıklarda aynı VOC yoğunluğuna maruz kaldığında farklılık gösterir. Sıcaklık değişimlerinin olumsuz etkilerini ortadan kaldırmak için devreler sıcaklık kompanzasyonu sağlayacak şekilde tasarlanmalıdır.

Bu veri seti, 8 MOX gaz sensör dizisinin 5 kopyasının kayıtlarını içermektedir. Her biri 8 MOX gaz sensör dizisi içeren ve aynı tasarımda olan 5 bağımsız kimyasal tespit ünitesinin cevabını ölçmek için aynı deney protokolü takip edilmiştir. Sensör çalışma sıcaklığı kontrolü ve sinyal koşullandırma için özel olarak tasarlanmış elektronik bileşenleri entegre eder. Aynı sensör tipinin tekrarları farklı sıcaklıklarda çalışır. Kanal, sensör tipi ve sensör tipine göre tespit edilen VOC türleri Tablo 5.1'de gösterilmiştir. Her birimde, her sensör tipinden 2 adet vardır.

Tablo 5.1. MOX sensör tipleri ve sensör tipine göre tespit edilen VOC türleri

Kanal	Sensor tipi	Sensör tipine göre tespit edilen VOC türleri
0	TGS2611	CO, etanol, etilen, metan
1	TGS2612	CO, etanol, etilen, metan, propan, bütan
2	TGS2610	propan, bütan
3	TGS2602	CO, etanol, etilen, metan, amonyak, hidrojen sülfid

Veri setinin referans makalesinde [167], sensör kayması problemi, standardizasyon yöntemleri kullanılarak kalibrasyonla incelenmiştir. Bu tez çalışmasında ise kalibrasyon düzeltme yöntemleri kullanılmadan öznitelik çıkarma, sınıflandırma ve regresyon yöntemleri kullanılarak doğruluğun artırılması üzerine çalışılmıştır. Sınıflandırma testleri gazlar arasında ayırım yaparken model doğruluğunu ölçmektedir, regresyon testleri ise konsantrasyon tahminlerinin doğruluğunu belirlemektedir. Farklı konsantrasyon değerleri

için karbon monoksit, etanol, etilen ve metan gazları ile toplam 640 farklı ölçüm yapılmıştır. Her bir gaz için sınıflandırma grupları, konsantrasyon seviyeleri ve konsantrasyon değerleri Tablo 5.2’de verilmektedir. Sınıflandırma grupları her 4 gaz için düşük seviye, orta seviye ve yüksek seviye konsantrasyon değerleri dikkate alınarak belirlenmiştir.

Tablo 5.2. Her bir VOC için sunulan konsantrasyon seviyelerine göre sınıflandırma grupları ve açıklamaları.

Gaz	Etilen			Etanol			Karbonmonoksit			Metan		
Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
Konsantrasyon Değerleri (ppm)	12,5	50	100	12,5	50	100	25	100	200	25	100	200
	25	62,5	112,5	25	62,5	112,5	50	125	225	50	125	225
	37,5	75	125	37,5	75	125	75	150	250	75	150	250
		87,5			87,5			175			175	

Farklı gaz ve farklı konsantrasyonlara ait gaz sensörlerinden değerlerin elde edilmesi için yapılan deney şu aşamalardan oluşmaktadır: Öncelikle, algılama haznesinde 50 saniye boyunca sabit bir hava akımı (bir taşıyıcı gaz) dolaşmıştır. Daha sonra, taşıyıcı gaz seçilen gaz ile sabit hava akışında istenilen konsantrasyon seviyesinde karıştırılmış ve elde edilen gaz karışımı 100 saniye boyunca sirküle edilmiştir. Son olarak, temizleme aşaması gerçekleştirilmiştir ve buhar, test haznesinden temiz hava sirkülasyonu ile sonraki 450 saniye boyunca temizlenmiştir. Her deneyin süresi 600 sn’dir ve her sensörün örnekleme frekansı 100 Hz.’dir. Bir ölçümde, bir sensörden 60.000 veri elde edilmiştir.

Referans makalesinde [167], aynı sensör tipinin tekrarları farklı sıcaklıklarda çalıştırılarak kullanılmıştır. Aynı veriler aynı anda iki kez ölçülmüştür. Bu nedenle, deneysel kurulum aslında bir algılama ünitesinde 4 sensörden oluşmaktadır. Ancak 4 sensör iki kez kullanılmıştır (ikiz sensörler) ve ilk dördü ana (*master*), diğer dördü de bağımlı (*slave*) olarak kullanılmıştır. Kalibrasyon düzeltme yöntemleri ile bir taraftaki verilerden hareketle diğer taraf onunla uyumlu hale getirilmeye çalışılarak kalibrasyon farklılıkları giderilmeye çalışılmıştır. Kalibrasyondan sonra konsantrasyon değerleri elde edilmiş ve karşılaştırmalar yapılmıştır. MOX gaz sensör dizileri arasındaki kalibrasyon transferi, sensörlerin sapması da dahil olmak üzere incelenerek sensör kayması azaltılmaya çalışılmıştır.


Kullanılan veri seti, sürüklenen sensör yanıtlarından oluşmaktadır. Bu sapmalar nedeniyle, tahmin ve sınıflandırma görevi zor bir veridir. Derin öğrenme uygulamalarında veri setinin boyutu ve çeşitliliği öğrenme için en önemli faktördür. Ne kadar çok veriye sahip

olursak, model o kadar iyi öğrenir. Daha büyük veriler, model performansındaki artışın yanı sıra ezberlemeyi de önleyecektir. Bu tezde, bu 4 sensörün veri seti çoğaltıldı. İlk 4 sensör ve sonraki 4 sensör birbiri ardına eklendi. Bu nedenle ilk 4 sensör ile 640, son 4 sensör ile 640 ölçüm yapılmıştır. Yani veri seti büyütülmüş ve 1280 ölçüm olarak alınmıştır. Ölçümler bu şekilde arttırılmıştır.


5.2 Ön İşleme Aşaması

Öncelikle veri seti, veri girişi için hazır hale getirildi. Sonrasında ise ön işleme aşaması gerçekleştirildi. İşaret ön işleme aşaması ile boyut indirgemenin yanı sıra, gürültünün ve sensör kayması problemlerinin de sinyal üzerindeki etkisi azaltılmaktadır. Ön işleme aşamasında, verilerin iletkenliğe dönüştürülmesi işlemi gerçekleştirildi. Tüm sensör yanıtlarının aynı koşullarda değerlendirilmesini sağlamak için referans noktaları ayarlanarak fark referans düzeltme yöntemi uygulandı, her bir sinyal aynı referans noktasından başlayacak şekilde tüm sinyaller başlangıç değerlerinden çıkarıldı. Sonrasında ise sinyal düzeltme işlemi gerçekleştirildi ve düzenli olarak örneklenen veri sinyallerinden en küçük kareler hatasını minimize edecek en uygun çizgi çıkarıldı. Boyut küçültmede, ön işleme aşamasından geçen gaz verilerinin yüksek boyutu veya fazlalığı nedeniyle sınıflandırma işlemine uygun hale getirilmesi için boyut küçültülmektedir. Normalleştirme ile, veriler genel veriler içinde ağırlıklandırılarak verilerin kolay yorumlanmasına olanak sağlanır. Sinyal ön işlemeye ilişkin çalışmalar aşağıda ayrıntılı olarak açıklanmaktadır.


Etilen için 4 sensörden elde edilen ham verilerin sinyalleri Şekil 5.1’de, bu verilerin iletkenliğe dönüşümü ile elde edilen sinyaller Şekil 5.2’de, referans düzeltme uygulandıktan sonra aynı referans noktasından başlayan ön işlemeli sinyaller Şekil 5.3’te ve sinyal düzeltme uygulandıktan sonra elde edilen sinyaller Şekil 5.4’te gösterilmektedir.




Şekil 5.1. Etilen için 4 MOX gaz sensörünün ham sinyalleri.



Şekil 5.2. Etilen için 4 MOS gaz sensörünün iletkenlik sinyalleri.



Şekil 5.3. Etilen için 4 MOS gaz sensörünün aynı referans noktasından başlayan iletkenlik (ön işlenmiş) sinyalleri.



Şekil 5.4. Etilen için 4 MOS gaz sensörünün sinyal düzeltmesi uygulandıktan sonra elde edilen iletkenlik sinyalleri

5.3 Ham Verilerin İşlenmesi

Ham verilerin işlenmesi şu şekildedir: MOX sensörlerinin sinyalleri incelendiğinde (Şekil 5.1) ilk 400 saniyenin bilgi içerdiği görülmektedir. 400 sn sonra elde edilen sinyal, test odasının temizlik aşamasında elde edilen sinyaldir. İlk 400 saniyeden sonra sinyaller yeterli bilgi içermediği için tüm ölçümlerin boyutları 400 sn'ye düşürülmüştür. LSTM'de sıralı veriler kullanıldığı için her sensörden elde edilen veri bir satır vektör olmak üzere bir ölçümde 4 sensörden elde edilen verilerle matris oluşumu gerçekleştirildi. 40.000 veriye (400 sn, 100 Hz. örnekleme frekansı) sahip 4 sensör arka arkaya alınmış ve bir ölçüm için 1×160000 boyutunda bir satır vektörü elde edilmiştir. Bu vektör ilk ölçümdür; yani, matrisin ilk satırıdır. Toplamda 1280 ölçüm olduğu için 1280 satır ve 160.000 sütundan oluşan bir matris oluşturulmuştur. Aşağı örnekleme yöntemi kullanılarak 100 kat veri küçültme yapılmıştır. Böylece matris boyutu 1280×1600 olarak elde edilmiştir. Yavaş sensör yanıtı nedeniyle, 100 faktörü ile aşağı örnekleme bilgi kaybına neden olmaz. Matrisin örnekleme hızı azaltıldı. Sınıflandırmada, konsantrasyon seviyeleri Tablo 5.2'de gösterildiği gibi 12 sınıfa ayrılmıştır. Etiket matrisi, giriş matrisinin yanıtıdır. Etiket matrisi 1280×1 boyutundadır. 1280×1600 boyutundaki giriş matrisi ile 1280×1 boyutundaki etiket matrisi birleştirilerek bir veri tabanı oluşturulmuştur. Daha sonra, bu veri tabanı Karar Ağacı, Doğrusal ve Karesel Ayırma Analizi, Naïve Bayes, SVM, k-En Yakın Komşu (*k-Nearest Neighbours*, *KNN*) ve Kolektif (*Ensemble*) Öğrenme algoritmaları ile sınıflandırmalar için kullanılmıştır. Sınıflandırma için test aşamasında 10 katlı çapraz doğrulama kullanılmıştır. Regresyonda her gazın 320 ölçümü vardır. Regresyon, her bir gaz örneğinin konsantrasyon değerleri için ayrı ayrı yapılmıştır. Regresyonda kullanılacak her bir gaz örneği için 320×1600 boyutunda giriş matrisleri ve 320×1 boyutunda etiket matrisleri oluşturulmuştur. Ortalama karesel hatalar elde edilirken Doğrusal Destek Vektör Regresyonu, Karar Ağacı Regresyonu, Kolektif Öğrenme Regresyonu, Gauss Süreci Regresyonu ve Doğrusal Regresyon yöntemleri kullanılmıştır.

5.4 Sensör Yanıtlarının Maksimum Değerlerine Göre Öznitelik Çıkarımı

Veri setine farklı öznitelik çıkarma yöntemleri uygulanmıştır. Çıkarılan bu farklı öznitelikler kullanıldığında elde edilen başarılar hem sınıflandırma hem de regresyon görevleri için karşılaştırılmıştır. Gaz sensör verilerinde en çok kullanılan öznitelik her bir sensör sinyalinin maksimum değeridir. Bu nedenle, öznitelik çıkarma yöntemi olarak sensör yanıtının maksimum değerleri alınmış ve 1280 ölçüm ve 4 maksimum sensör değerlerini


içeren bir matris oluşturulmuştur. Öznitelik çıkarma yöntemi olarak sensör yanıtlarının maksimum değerleri kullanıldığı zaman öznitelik uzayı 1600'den 4'e düşmektedir. Bu nedenle, her ölçümün 4 özneliği olmaktadır. Gaz örneklerinin konsantrasyon düzeylerinin sınıflandırılması için 1280*4 boyutunda bir matris elde edilmiştir. Ancak regresyonda karbon monoksit, etilen, etanol ve metan gazlarının her biri için ayrı ayrı 320*4 boyutunda matrisler elde edilmiştir. Gaz örneklerindeki konsantrasyon seviyelerine (Tablo 3.2'de verilen 12 sınıf) göre sınıflandırmalar yapılmış ve bu sınıflandırmaların doğruluğu incelenmiştir. Sınıflandırmalar daha önce belirtilen sınıflandırma yöntemleri kullanılarak yapılmıştır. Sınıflandırma başarısı, 10 katlı çapraz doğrulama yöntemi kullanılarak elde edilmiştir. Regresyon için ek bir sınıflandırma modeli de gerçekleştirilmiş ve her bir uçucu maddenin konsantrasyon değerleri için ayrı sınıflandırma yapılmıştır. Regresyon çalışmaları ile gazların her bir konsantrasyon değerine ne kadar yakın olduğu tespit edilmeye çalışılmıştır. Regresyon görevinde, gazların konsantrasyon değerlerini tahmin etmek için beş farklı regresyon yöntemi kullanılarak ortalama karesel hatalar (MSE) elde edilmiştir.

5.5 LSTM Ağlarının Tam Bağlantılı Katmanından Öznitelik Çıkarımı

Bu çalışmada geliştirilen yöntemlerden birisi, LSTM ağlarının tam bağlantılı katmanının giriş verilerini kullanarak öznitelik çıkarımının yapılmasıdır. Şekil 5.5, sınıflandırma için kullanılan LSTM ağ mimarisini göstermektedir. LSTM ağı, dizi veya zaman serisi verilerini ağa giren bir dizi giriş katmanı ve zaman serisi veya dizi verilerinin zaman adımları arasındaki uzun vadeli bağımlılıkları öğrenen bir LSTM katmanı ile başlar. Ağ, tam bağlantılı bir katman, bir softmax katmanı ve sınıf etiketlerini tahmin etmek için bir sınıflandırma çıkış katmanı ile sona erer. Şekil 5.6, regresyon için kullanılan LSTM ağ mimarisini göstermektedir. LSTM ağı, bir dizi giriş katmanı, bir LSTM katmanı ile başlar. Ağ, tam bağlantılı bir katman ve bir regresyon çıkış katmanı ile sona erer. Bu bölümde, LSTM ağının tam bağlantılı katmanından veriler alınarak bir öznitelik çıkarımı yapılmakta ve daha sonra bu veriler için sınıflandırma ve regresyon algoritmaları kullanılarak sınıflandırma ve tahmin analizleri yapılmaktadır.



Şekil 5.5. Sınıflandırma için LSTM Ağ Mimarisi



Şekil 5.6. Regresyon için LSTM Ağ Mimarisi

Dizi ham verilerini sınıflandırmak ve dizi verilerinin bireysel zaman adımlarına dayalı tahminler yapmak için, 1280 dizi 4×400 boyutlu bir matris (1280×1600) oluşturuldu. Gaz örneklerindeki konsantrasyon seviyelerine göre oluşturulan tepki matrisi 1280×1 boyutlu bir vektördür. Eğitim verileri, 12 sınıf konsantrasyon seviyesi için zaman serisi verilerini içermektedir. LSTM ağı bir öznitelik çıkarıcı olarak kullanıldığı zaman her bir ölçümden 12 öznitelik elde edilmiştir ve çıkarılan bu öznitelikler ile 1280×12 boyutunda bir matris elde edilmiştir. 12 konsantrasyon seviyesi sınıfına karşılık gelen “1”, “2”, “3”, ..., “12” etiketlerinin kategorik bir vektörünü içeren bir yanıt matrisi oluşturulmuştur. LSTM ağ mimarisi şu şekildedir: 4 sensör kullanıldığı için giriş verilerinin boyutu 4 boyutlu diziler olarak belirlenmiştir. Gizli birim sayısı 100’dir ve LSTM katmanının çıkış modu ‘son’ olarak ayarlanmıştır. Daha sonra, tam bağlantılı bir katman, ardından bir softmax katmanı ve bir sınıflandırma katmanı dahil edilerek 12 sınıf belirlenmiştir. Dizi giriş katmanının boyutu, giriş verilerinin öznitelik sayısına göre ayarlanmıştır. Böylece 1280×12 boyutunda bir matris elde edilmiştir. 1600 (4 sensör $\times$ 400 saniye) veriden, LSTM ağı kullanılarak 12 öznitelik çıkarılmıştır. Eğitim seçenekleri şu şekildedir: Optimizasyon algoritması ‘adam’ olarak belirtilmiştir. Uyarlanabilir Moment Tahmini (*Adaptive Moment Estimation, Adam*), karelerin ortalamasının karekökü yayılımı (*Root Mean Square Propagation, RMSprop*) ve momentumu birleştiren bir algoritmadır ve her bir parametre için dinamik bir şekilde öğrenme oranını (*learning rate*) günceller. Veri seti grubu (*mini-batch*) parametresi olarak belirlenen değer ile öğrenme küçük gruplar üzerinde gerçekleştirilir, bu nedenle eğitim Merkezi İşlem Birimi (*Central Processing Unit, CPU*) için daha uygundur. Yürütme ortamı “cpu” olarak belirtilmiştir. Gradyan eşiği, maksimum devir sayısı (*epoch*) ve mini-yığın boyutu sırasıyla 1, 2000 ve 27 olarak ayarlanmıştır. Verilerin karıştırılması “asla” olarak ayarlanmıştır, böylece veriler sıra uzunluğuna göre sıralanmış olarak kalmaktadır. Dizi uzunluğu ‘en uzun’ olarak belirtilmiştir, buna göre veriler, en uzun dizilerle aynı uzunluğa sahip olacak şekilde doldurulur. Sınıflandırmada öznitelikler tam bağlantılı katmandan alınmıştır. Daha sonra LSTM ağından elde edilen öznitelikler ile oluşturulan veriler kullanılarak geleneksel sınıflandırma yöntemlerine göre sınıflandırmalar yapılmıştır.


Regresyon için, dizi verilerinden sayısal değerleri tahmin etmek üzere derin sinir ağını eğitmek için bir LSTM ağı kullanıldı. 4*400 boyutlu matrislerden oluşan 320 dizi oluşturuldu. Her bir gaz örneği için konsantrasyon değerlerine göre oluşturulan yanıt matrisi 320*1 boyutunda olan matrislerdir. Veri seti, her bir gaz örneğinin ayrı ayrı konsantrasyon değerleri için zaman serisi verilerini içermektedir. Regresyonda tam bağlantılı katmandan öznitelikler çıkarılırken, alınan öznitelikler matrise dönüştürülerek her gaz için 320*400 boyutunda bir matris elde edilmiştir. 1600 (4 sensör × 400 sn) veriden, LSTM ağı kullanılarak 400 öznitelik çıkarılmıştır. Öznitelikleri içeren matris ve etiket matrisi, regresyon için bir veri tabanı oluşturmak üzere birleştirildi. LSTM katmanında gizli birim sayısı 200, tam bağlantılı katmanın boyutu 50 ve seyreltme (*dropout*) oranı katmanı 0,5 seyreltme olasılığına sahiptir. Giriş matrisi olarak tam bağlantılı katmandan elde edilen verilerin kullanıldığı LSTM ağında, maksimum devir sayısı 2000, mini-yığın boyutu ise 64 olarak belirlenmiştir. Optimizasyon algoritması ‘adam’ ve öğrenme oranı 0,01 olarak belirlendi. LSTM’nin tam bağlantılı katmanından elde edilen çıktılar kullanılarak regresyon gerçekleştirilmiş ve daha sonra belirtilen regresyon yöntemleri kullanılarak konsantrasyon değerleri tahmin edilmiştir. LSTM ağı ile yapılan sınıflandırma ve regresyonlarda en yüksek başarı oranları ve en az MSE yukarıda belirtilen parametreler kullanılarak gerçekleştirilmiştir.


5.6 TCN Mimarisinin Tam Bağlantılı Katmanından Öznitelik Çıkarımı

Çalışmada uygulanan üçüncü öznitelik çıkarma yönteminde ise LSTM ağının tam bağlantılı katmanından elde edilen öznitelikler TCN modeline giriş verisi olarak uygulanmıştır ve TCN’nin tam bağlantılı katmanından elde edilen öznitelikler ise gaz örneklerinin konsantrasyon seviyelerine göre sınıflandırılmasında ve konsantrasyon değerlerine göre regresyon yapılmasında kullanılmıştır. LSTM ve TCN algoritmalarının tam bağlantılı katmanından elde edilen verileri kullanan öznitelik çıkarma yöntemi için veri işleme akış şeması Şekil 5.7’de gösterilmektedir. LSTM ve TCN’deki ağ yapıları ve hiperparametre ayarlamaları ile ilgili yapılan işlemler için akış şeması ise Şekil 5.8’de gösterilmektedir. Sınıflandırmada, LSTM ağından çıkarılan öznitelikleri (1280*12) TCN’ye giriş olarak uygulamak için 1*12 boyutlu matrislerden 1280 dizi oluşturuldu. Gaz örneklerindeki konsantrasyon seviyelerine göre oluşturulan tepki matrisi 1280*1 boyutlu vektördür. TCN’nin ağ yapısı, Bölüm 4’te ayrıntılı bir şekilde açıklanmıştır. Sınıflandırma için kullanılan TCN mimarisinde, girişe kayan evrişim filtreleri uygulayarak öznitelikleri öğrenen bir TCN katmanından sonra tam bağlantılı bir katman, bir softmax katmanı ve gaz


verilerini konsantrasyon seviyelerine göre ayırmak için bir sınıflandırma çıktı katmanı ile dizi modelleme görevi gerçekleştirilmektedir. 1 boyutlu evrişim katmanları için filtre sayısı ve filtre boyutu 10'a ayarlanmıştır ve uzaysal bırakma katmanları için seyreltme faktörü 0,005'e ayarlanmıştır. Uygulanan filtre sayısı 10 olduğu için, TCN'nin tam bağlantılı katmanından her bir ölçüm için 120 öznitelik çıkarılmıştır ve böylece 1280*120 boyutlu bir matris elde edilmiştir. Eğitim seçenekleri aşağıdaki gibidir: Optimizasyon algoritması 'adam' olarak ayarlanmıştır. Maksimum devir sayısı ve mini-yığın boyutu sırasıyla 200 ve 1 olarak ayarlanmıştır. TCN'nin tam bağlantılı katmanından elde edilen matris ve yanıt matrisi ile bir veri tabanı oluşturulmuştur. Bu veri tabanı ile geleneksel sınıflandırma yöntemlerine göre sınıflandırmalar yapılarak birbirleriyle karşılaştırılmıştır.

Regresyonda, LSTM ağından çıkarılan öznitelikleri (320*400) TCN'ye giriş olarak uygulamak için 1*400 boyutlu matrislerden 320 dizi oluşturulmuştur. 320*1 boyutlu matris olan tepki matrisi, her bir gaz örneğinin konsantrasyon değerlerini içermektedir. Veri seti, her bir uçucunun konsantrasyon değerleri için ayrı ayrı zaman serisi verilerini içerir. Regresyon için kullanılan TCN mimarisinde, TCN katmanından sonra gaz verilerinin konsantrasyon değerlerini tahmin etmek için tam bağlantılı bir katman ve bir regresyon çıkış katmanı ile regresyon görevi gerçekleştirilmektedir. 1-boyutlu evrişim katmanları için filtre sayısı ve filtre boyutu 10 olarak belirlenmiştir. Uzaysal seyreltme katmanları için seyreltme faktörü 0,005 olarak belirlendi. TCN'de kullanılan eğitim seçenekleri ise şu şekildedir: Optimizasyon algoritması 'adam' olarak belirlenmiştir. Maksimum devir sayısı ve mini-yığın boyutu sırasıyla 200 ve 1 olarak belirtildi. Uygulanan filtre sayısı 10 olduğu için, TCN'nin tam bağlantılı katmanından her bir ölçüm için 4000 öznitelik çıkarılmıştır ve böylece 320*4000 boyutlu bir matris elde edilmiştir. LSTM'nin tam bağlantılı katmanından elde edilen çıktıların TCN'ye giriş olarak kullanıldığı ve TCN'nin tam bağlantılı katmanından elde edilen verilerin çıkış olarak kullanıldığı yapıda, gaz örneklerinin konsantrasyon değerlerine göre tahmin edilmesi için geleneksel regresyon yöntemleri kullanıldı ve elde edilen sonuçlar birbirleriyle karşılaştırıldı. LSTM ve TCN ile yapılan sınıflandırma ve regresyonlarda en yüksek başarı oranları ve en az MSE değerleri yukarıda belirtilen parametreler kullanılarak gerçekleştirilmiştir.





Şekil 5.7. LSTM ve TCN'nin tam bağlantılı katman verilerini kullanan öznitelik çıkarma yöntemi için veri işlemenin akış şeması.



Şekil 5.8. LSTM ve TCN’deki ağ yapılarının işlemleri için akış şeması

6. TARTIŞMA VE YORUM

Bu çalışmada, tüm sensörler dahil olmak üzere karbon monoksit, etilen, etanol ve metan gazı örneklerinin başarı oranları çeşitli sınıflandırma yöntemleri kullanılarak konsantrasyon seviyelerine göre incelenmiştir. Öncelikle sinyal düzeltme uygulanmadan başarı oranları incelenmiştir, sonrasında ise sinyal düzeltme uygulandığı zaman elde edilen başarı oranları incelenmiş ve birbirleriyle karşılaştırılmıştır. Sınıflandırma yapılırken öncelikle ham verilerin doğruluk oranları elde edilmiştir. Ham veriler için başarı oranları incelendiğinde, sinyal düzeltme uygulanmadan önce en yüksek doğruluk oranı 76,7% ile SVM sınıflandırma algoritmasında elde edilmiştir. Sinyal düzeltme uygulandıktan sonra ise en yüksek doğruluk oranının 82,4% ile SVM sınıflandırma algoritmasında elde edildiği görülmektedir. 6 farklı sınıflandırma yöntemi kullanılarak, sinyal düzeltme uygulanmadığında ve sinyal düzeltme uygulandığında ham verilere dayalı olarak gaz örneklerinin konsantrasyon seviyelerine göre elde edilen başarı oranları sırasıyla Tablo 6.1 ve Tablo 6.2’de gösterilmiştir. Bu sonuçlar, öznelilik uzayı büyük olduğunda SVM’nin diğer yöntemlere göre daha sağlam bir algoritma olduğu şeklinde yorumlanabilir. Öznelilik sayısı sınıf sayısından çok fazla olduğunda SVM algoritması diğer yöntemlere göre oldukça başarılıdır. Ayrıca sinyal düzeltme uygulandığında sınıflandırmadaki başarı oranlarının arttığı görülmektedir. SVM, yüksek genelleme performansına sahip verimli sınıflandırma algoritmalarından biridir [169-174].

Tablo 6.1. Sinyal düzeltme uygulanmadığı zaman ham veriler kullanılarak gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.

Algoritmalar	Doğruluk	Tahmin Hızı	Eğitim Zamanı	Parametreler
Karar Ağacı	63,0%	~570 obs/sn	126,72 sn	Ön Ayar: İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	40,9%	~290 obs/sn	140,56 sn	Ön Ayar: Doğrusal Ayırma Kovaryans Yapısı: Tam
Naïve Bayes	28,0%	~6.1 obs/sn	2501,9 sn	Ön Ayar: Kernel Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Kernel Kategorik Tahminciler için Dağıtım Adı: Çok Değişkenli, Çok Terimli Kernel Türü: Gauss
SVM	76,7%	~120 obs/sn	736,06 sn	Ön Ayar: Kübik SVM Kernel Fonksiyonu: Kübik Kernel Ölçeği: Otomatik Kutu Kısıtlama Düzeyi: 1 Çoklu Sınıf Yöntemi: Bire Karşı Bir Verileri Standartlaştırma: Doğru
KNN	71,5%	~200 obs/sn	678,34 sn	Ön Ayar: Fine KNN Komşu Sayısı: 1 Mesafe Metriği: Öklid Mesafe Ağırlığı: Eşit Verileri Standartlaştırma: Doğru
Kolektif Öğrenme	76,5%	~500 obs/sn	858,77 sn	Ön Ayar: Torbalama Ağaçları Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30

Tablo 6.2. Sinyal düzeltme uygulandığı zaman ham veriler kullanılarak gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.

Algoritmalar	Doğruluk	Tahmin Hızı	Eğitim Zamanı	Parametreler
Karar Ağacı	70,2%	~440 obs/sn	85,363 sn	Ön Ayar: İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	57,2%	~360 obs/sn	165,39 sn	Ön Ayar: Doğrusal Ayırma Kovaryans Yapısı: Tam
Naïve Bayes	59,1%	~5.1 obs/sn	2213,6 sn	Ön Ayar: Kernel Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Kernel Kategorik Tahminciler için Dağıtım Adı: Uygulanamaz Kernel Türü: Gauss
SVM	<u>82,4%</u>	~200 obs/sn	485,71 sn	Ön Ayar: Karesel SVM Kernel Fonksiyonu: Karesel Kernel Ölçeği: Otomatik Kutu Kısıtlama Düzeyi: 1 Çoklu Sınıf Yöntemi: Bire Karşı Bir Verileri Standartlaştırma: Doğru
KNN	77,9%	~210 obs/sn	1276,2 sn	Ön Ayar: Ağırlıklı KNN Komşu Sayısı: 10 Mesafe Metriği: Öklid Mesafe Ağırlığı: Kareli ters Verileri Standartlaştırma: Doğru
Kolektif Öğrenme	79,6%	~540 obs/sn	2395,3 sn	Ön Ayar: Torbalama Ağaçları Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30

Ham veriler ile gerçekleştirilen sınıflandırmadan sonra sensörlerin maksimum değerleri kullanılarak öznitelik çıkarma işlemi gerçekleştirilmiştir. Öznitelik çıkarma ile girdi olarak sağlanan sensör verilerini kullanarak türetilmiş değerler (öznitelikler) oluşturulmuştur. Elde edilen değerlerin bilgilendirici ve gereksiz verilerden arındırılmış olması, öğrenme sürecini kolaylaştırması ve daha iyi yorumlanması amaçlanmıştır. Sınıflandırma için veri tabanı oluşturulurken, öznitelik olarak seçilen maksimum değerler

giriş matrisi olarak kullanılırken etiket matrisi olarak gazların konsantrasyon seviyeleri kullanılmıştır. Tüm sensörler dahil edilerek gaz örneklerinin konsantrasyon seviyelerine göre sınıflandırma işlemi gerçekleştirilmiş, sinyallere öznitelik alt seçimi uygulanmamıştır. En yüksek doğruluk oranı 83,6% ile SVM sınıflandırmasında elde edilirken, sinyal düzeltme uygulanmadan önce bu oran 81,1% ile yine SVM sınıflandırma yönteminde elde edilmiştir. Belirtilen sınıflandırma yöntemlerine göre elde edilen doğruluk oranları Tablo 6.3 ve Tablo 6.4'te verilmiştir. Burada sinyal düzeltme ile tüm sınıflandırma yöntemlerinde başarı oranlarında artış olduğu görülmektedir. Buna ek olarak, ham verilere göre de kıyasladığımız zaman sensör cevabının maksimum değeri olarak seçilen öznitelikler kullanıldığında SVM algoritmasının başarısının yanında tüm algoritmaların başarıları da artmaktadır. Buradan verilerin ilgisiz bilgilere sahip olduğu anlaşılmaktadır. İlgili özellikler artırılırsa başarı da artacaktır. Bu nedenle de çalışmada, derin ağ yapılarından olan LSTM ve TCN kullanılarak düşük ve yüksek seviyeli özniteliklere ulaşılması hedeflenmiştir. Ayrıca, kullanılan bu yöntemle daha az sayıda öznitelik uzayına geçiş olduğu için de başarıda artışın olduğu düşünülmektedir.

Sınıflandırmada kullanılan ve geliştirilen diğer öznitelik çıkarma yöntemi ise, LSTM ağının tam bağlantılı katmanının giriş verilerinden çıkarılan öznitelikleri kullanmaktır. Gaz örneklerini konsantrasyon seviyelerine göre sınıflandırırken önerilen bu metodoloji ile en yüksek doğruluk oranı 93,6% ile SVM sınıflandırma algoritmasında elde edilmiştir. Sinyal düzeltme kullanmadan önce elde edilen en yüksek doğruluk ise yine SVM sınıflandırma yönteminde 90,8% ile sağlanmıştır. LSTM ağının tam bağlantılı katmanından elde edilen özniteliklere bağlı olarak 6 farklı sınıflandırma yöntemi kullanılarak elde edilen başarı oranları Tablo 5.5 ve Tablo 6.6'da görülmektedir. Kullanılan diğer yöntemlere göre tüm sınıflandırma algoritmalarında gözle görülür bir başarı oranı elde edilmiştir. Derin ağ yapılarından LSTM ağlarının, zaman serisi verilerinde oldukça başarılı olduğu görülmektedir. Önerilen öznitelik çıkarma yöntemi, yüksek ve düşük seviyeli öznitelikleri çıkararak ayrılabilir öznitelik uzayını oluşturmuştur. Böylece, sınıflandırma başarısında artış olmuştur.

Tablo 6.3. Sinyal düzeltme uygulanmadığı zaman öznitelik çıkarımında maksimum değerler kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.

Algoritmalar	Doğruluk	Tahmin Hızı	Eğitim Zamanı	Parametreler
Karar Ağacı	74,8%	~7200 obs/sn	2,9209 sn	Ön Ayar: İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	75,6%	~8400 obs/sn	4,0517 sn	Ön Ayar: Karesel Ayırma Kovaryans Yapısı: Tam
Naïve Bayes	74,1%	~1600 obs/sn	11,316 sn	Ön Ayar: Kernel Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Kernel Kategorik Tahminciler için Dağıtım Adı: Çok Değişkenli, Çok Terimli Kernel Türü: Gauss
SVM	81,1%	~880 obs/sn	28,756 sn	Ön Ayar: Karesel SVM Kernel Fonksiyonu: Karesel Kernel Ölçeği: Otomatik Kutu Kısıtlama Düzeyi: 1 Çoklu Sınıf Yöntemi: Bire Karşı Bir Verileri Standartlaştırma: Doğru
KNN	78,8%	~11000 obs/sn	37,228 sn	Ön Ayar: Ağırlıklı KNN Komşu Sayısı: 10 Mesafe Metriği: Öklid Mesafe Ağırlığı: Kareli ters Verileri Standartlaştırma: Doğru
Kolektif Öğrenme	77,7%	~1700 obs/sn	48,609 sn	Ön Ayar: Torbalama Ağaçları Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30

Tablo 6.4. Sinyal düzeltme uygulandığı zaman öznelilik çıkarımında maksimum değerler kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.

Algoritmalar	Doğruluk	Tahmin Hızı	Eğitim Zamanı	Parametreler
Karar Ağacı	77,5%	~2600 obs/sn	5,2481 sn	Ön Ayar: İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	78,4%	~5800 obs/sn	37,842 sn	Ön Ayar: Karesel Ayırma Kovaryans Yapısı: Tam
Naïve Bayes	76,3%	~940 obs/sn	55,569 sn	Ön Ayar: Kernel Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Kernel Kategorik Tahminciler için Dağıtım Adı: Uygulanamaz Kernel Türü: Gauss
SVM	<u>83,6%</u>	~1400 obs/sn	89,113 sn	Ön Ayar: Karesel SVM Kernel Fonksiyonu: Karesel Kernel Ölçeği: Otomatik Kutu Kısıtlama Düzeyi: 1 Çoklu Sınıf Yöntemi: Bire Karşı Bir Verileri Standartlaştırma: Doğru
KNN	79,8%	~9000 obs/sn	124,46 sn	Ön Ayar: Ağırlıklı KNN Komşu Sayısı: 10 Mesafe Metriği: Öklid Mesafe Ağırlığı: Kareli ters Verileri Standartlaştırma: Doğru
Kolektif Öğrenme	80,5%	~3300 obs/sn	165,04 sn	Ön Ayar: Torbalama Ağaçları Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30

Tablo 6.5. Sinyal düzeltme uygulanmadığı zaman öznelilik çıkarımında LSTM ağının tam bağlantılı katmanı kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.

Algoritmalar	Doğruluk	Tahmin Hızı	Eğitim Zamanı	Parametreler
Karar Ağacı	86,6%	~5600 obs/sn	4,8225 sn	Ön Ayar: İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	89,0%	~2100 obs/sn	5,5793 sn	Ön Ayar: Karesel Ayırma Kovaryans Yapısı: Tam
Naïve Bayes	87,7%	~460 obs/sn	35,43 sn	Ön Ayar: Kernel Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Kernel Kategorik Tahminciler için Dağıtım Adı: Çok Değişkenli, Çok Terimli Kernel Türü: Gauss
SVM	90,8%	~830 obs/sn	26,739 sn	Ön Ayar: Karesel SVM Kernel Fonksiyonu: Karesel Kernel Ölçeği: Otomatik Kutu Kısıtlama Düzeyi: 1 Çoklu Sınıf Yöntemi: Bire Karşı Bir Verileri Standartlaştırma: Doğru
KNN	90,2%	~6800 obs/sn	44,146 sn	Ön Ayar: Ağırlıklı KNN Komşu Sayısı: 10 Mesafe Metriği: Öklid Mesafe Ağırlığı: Kareli ters Verileri Standartlaştırma: Doğru
Kolektif Öğrenme	90,1%	~610 obs/sn	68,356 sn	Ön Ayar: Alt Uzak KNN Kolektif Yöntem: Alt Uzak Öğrenici Türü: En Yakın Komşular Öğrenici Sayısı: 30 Alt Uzak Boyutu: 6

Tablo 6.6. Sinyal düzeltme uygulandığı zaman öznitelik çıkarımında LSTM ağının tam bağlantılı katmanı kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.

Algoritmalar	Doğruluk	Tahmin Hızı	Eğitim Zamanı	Parametreler
Karar Ağacı	89,1%	~15000 obs/sn	3,9624 sn	Ön Ayar: İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	92,2%	~11000 obs/sn	4,8154 sn	Ön Ayar: Doğrusal Ayırma Kovaryans Yapısı: Tam
Naïve Bayes	91,2%	~530 obs/sn	25,552 sn	Ön Ayar: Kernel Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Kernel Kategorik Tahminciler için Dağıtım Adı: Uygulanamaz Kernel Türü: Gauss
SVM	<u>93,6%</u>	~2000 obs/sn	36,253 sn	Ön Ayar: Kübik SVM Kernel Fonksiyonu: Kübik Kernel Ölçeği: Otomatik Kutu Kısıtlama Düzeyi: 1 Çoklu Sınıf Yöntemi: Bire Karşı Bir Verileri Standartlaştırma: Doğru
KNN	92,5%	~5800 obs/sn	42,936 sn	Ön Ayar: Ağırlıklı KNN Komşu Sayısı: 10 Mesafe Metriği: Öklid Mesafe Ağırlığı: Kareli ters Verileri Standartlaştırma: Doğru
Kolektif Öğrenme	93,0%	~810 obs/sn	66,542 sn	Ön Ayar: Alt Uzay K-EYK Kolektif Yöntem: Alt Uzay Öğrenici Türü: En Yakın Komşular Öğrenici Sayısı: 30 Alt Uzay Boyutu: 6

Sınıflandırmada önerilen son öznitelik çıkarma yöntemi ise, LSTM ağının tam bağlantılı katmanından çıkarılan özniteliklerin TCN'ye giriş olarak verilmesi ve TCN'nin tam bağlantılı katmanından çıkarılan özniteliklerin ise gaz örneklerinin konsantrasyon seviyelerine göre sınıflandırılmasında kullanılmasıdır. Çalışmada, bu metodolojiden kısaca LSTMFCL-TCNFCL olarak söz edilmektedir. Önerilen bu metodoloji ile en yüksek doğruluk oranı 94,7% ile SVM sınıflandırma algoritmasında elde edilmiştir. Sinyal düzeltme

kullanmadan önce elde edilen en yüksek doğruluk ise yine SVM sınıflandırma yönteminde 91,5% ile sağlanmıştır. Kullanılan diğer yöntemlere göre en iyi başarı oranı bu geliştirilen metodoloji ile elde edilmiştir. Elde edilen başarı oranları Tablo 6.7 ve Tablo 6.8’de gösterilmektedir. Bu öznelik çıkarma yönteminde LSTM ağının yarattığı etki TCN ile güçlendirilerek sınıflandırmada en yüksek başarının elde edilmesi sağlanmıştır. Veri seti analiz edildiğinde, yeni yöntem daha güçlü öznelik çıkarma yeteneği göstermektedir ve gaz konsantrasyonlarını iyi bir şekilde tespit edebilmektedir. Önerilen yöntemle, yüksek ve düşük seviyeli öznelikler çıkarılarak ayrılabilir öznelik uzayı oluşturulmuştur. 1-B evrişim katmanı, 1-B girişe kayan evrişim filtreleri uygulayarak öznelikleri öğrenmektedir. 1-B evrişimli katmanları kullanmak, tekrarlayan katmanları kullanmaktan daha hızlı olmaktadır; yinelenen katmanlar, girdinin zaman adımlarını yinelerken evrişimli katmanlar, girişi tek bir işlemle işleyebilmektedir. SVM, doğrusal olmayan sorunları çözmek için farklı bir çekirdek fonksiyonuna sahiptir. Bu çalışmada da sınıflandırma problemi doğrusal olmadığı için gaz verileri için ayrılabilir bir hiper yüzey bulma şansı oluşmuştur. Buna ek olarak, SVM algoritması destek vektörleri kullanıldığı için aykırı değerlerden veya gürültülü verilerden etkilenmez. Bundan dolayı da iyi bir genelleme kabiliyetine sahiptir ve bu da ezberlemeyi önler. Bu nedenlerle, sınıflandırmada gaz verileri için SVM yönteminin daha başarılı olduğu yorumlanmıştır. Karar Ağacı, Doğrusal ve Karesel Ayırma Analizi, Naïve Bayes, SVM, KNN ve Kolektif Öğrenme algoritmaları kullanılarak, ham veriler ve uygulanan öznelik çıkarma yöntemlerine göre sinyal düzeltme uygulanmadığında ve sinyal düzeltme uygulandığında, gaz örneklerinin konsantrasyon seviyelerine göre elde edilen başarılı oranlarının karşılaştırmalı analizi sırasıyla Tablo 6.9 ve Tablo 6.10’da yer almaktadır.

Tablo 6.7. Sinyal düzeltme uygulanmadığı zaman öznelik çıkarımında LSTMFCL-TCNFCL modeli kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.

Algoritmalar	Doğruluk	Tahmin Hızı	Eğitim Zamanı	Parametreler
Karar Ağacı	87,7%	~6500 obs/sn	13,177 sn	Ön Ayar: İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	90,9%	~3100 obs/sn	20,44 sn	Ön Ayar: Doğrusal Ayırma Kovaryans Yapısı: Tam
Naïve Bayes	88,5%	~300 obs/sn	30,477 sn	Ön Ayar: Gauss Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Gauss Kategorik Tahminciler için Dağıtım Adı: Uygulanamaz
SVM	<u>91,5%</u>	~1200 obs/sn	62,933 sn	Ön Ayar: Karesel SVM Kernel Fonksiyonu: Karesel Kernel Ölçeği: Otomatik Kutu Kısıtlama Düzeyi: 1 Çoklu Sınıf Yöntemi: Bire Karşı Bir Verileri Standartlaştırma: Doğru
KNN	91,0%	~2400 obs/sn	125,44 sn	Ön Ayar: Ağırlıklı KNN Komşu Sayısı: 10 Mesafe Metriği: Öklid Mesafe Ağırlığı: Kareli ters Verileri Standartlaştırma: Doğru
Kolektif Öğrenme	91,1%	~1800 obs/sn	221,82 sn	Ön Ayar: Torbalama Ağaçları Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30

Tablo 6.8. Sinyal düzeltme uygulandığı zaman öznitelik çıkarımında LSTMFCL-TCNFCL modeli kullanıldığında gaz örneklerindeki konsantrasyon seviyelerine göre başarı oranları.

Algoritmalar	Doğruluk	Tahmin Hızı	Eğitim Zamanı	Parametreler
Karar Ağacı	91,8%	~9100 obs/sn	8,3824 sn	Ön Ayar: İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	93,9%	~5900 obs/sn	10,124 sn	Ön Ayar: Doğrusal Ayırma Kovaryans Yapısı: Tam
Naïve Bayes	92,8%	~390 obs/sn	22,814 sn	Ön Ayar: Gauss Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Gauss Kategorik Tahminciler için Dağıtım Adı: Uygulanamaz
SVM	<u>94,7%</u>	~1200 obs/sn	37,403 sn	Ön Ayar: Karesel SVM Kernel Fonksiyonu: Karesel Kernel Ölçeği: Otomatik Kutu Kısıtlama Düzeyi: 1 Çoklu Sınıf Yöntemi: Bire Karşı Bir Verileri Standartlaştırma: Doğru
KNN	94,0%	~2200 obs/sn	124,32 sn	Ön Ayar: Ağırlıklı KNN Komşu Sayısı: 10 Mesafe Metriği: Öklid Mesafe Ağırlığı: Kareli ters Verileri Standartlaştırma: Doğru
Kolektif Öğrenme	94,2%	~2100 obs/sn	229,79 sn	Ön Ayar: Torbalama Ağaçları Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30 Örneklenecek Tahmin Edici Sayısı: Tümünü Seç

Tablo 6.9. Sinyal düzeltme uygulanmadığı zaman önerilen yöntem ile geleneksel yöntemlerin elde edilen başarı oranlarının karşılaştırılması

Algoritmalar	Ham Verilere ve Seçilen Parametrelere Dayalı Doğruluk (%)	Öznitelik Olarak Maksimum Değerlerin Seçimine ve Seçilen Parametreler Dayalı Doğruluk	LSTM'nin Tam Bağlı Katmanından Çıkarılan Özniteliklere ve Seçilen Parametrelere Dayalı Doğruluk	LSTMFCL-TCNFCL'den Çıkarılan Özniteliklere ve Seçilen Parametrelere Dayalı Doğruluk
Karar Ağacı	63,0% İnce Ağaç Maksimum Bölünme Sayısı: 100	74,8% İnce Ağaç Maksimum Bölünme Sayısı: 100	86,6% İnce Ağaç Maksimum Bölünme Sayısı: 100	87,7% İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	40,9% Doğrusal Ayırma	75,6% Karesel Ayırma	89,0% Karesel Ayırma	90,9% Doğrusal Ayırma
Naïve Bayes	28,0% Kernel Naïve Bayes Kernel Türü: Gauss	74,1% Kernel Naïve Bayes Kernel Türü: Gauss	87,7% Kernel Naïve Bayes Kernel Türü: Gauss	88,5% Gauss Naïve Bayes Kernel Türü: Gauss
SVM	76,7% Kernel Fonksiyonu: Kübik Çoklu Sınıf Yöntemi: Bire Karşı Bir	81,1% Kernel Fonksiyonu: Karesel Çoklu Sınıf Yöntemi: Bire Karşı Bir	90,8% Kernel Fonksiyonu: Karesel Çoklu Sınıf Yöntemi: Bire Karşı Bir	91,5% Kernel Fonksiyonu: Karesel Çoklu Sınıf Yöntemi: Bire Karşı Bir
KNN	71,5% k= 1 Öklid	78,8% k = 10 Öklid	90,2% k=10 Öklid	91,0% k=10 Öklid
Kolektif Öğrenme	76,5% Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30	77,7% Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30	90,1% Kolektif Yöntem: Alt Uzak Öğrenici Türü: En Yakın Komşular Öğrenici Sayısı: 30 Alt Uzak Boyutu: 6	91,1% Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30

Tablo 6.10. Sinyal düzeltme uygulandığı zaman önerilen yöntem ile geleneksel yöntemlerin elde edilen başarı oranlarının karşılaştırılması

Algoritmalar	Ham Verilere ve Seçilen Parametrelere Dayalı Doğruluk (%)	Öznitelik Olarak Maksimum Değerlerin Seçimine ve Seçilen Parametreler Dayalı Doğruluk	LSTM'nin Tam Bağlı Katmanından Çıkarılan Özniteliklere ve Seçilen Parametrelere Dayalı Doğruluk	LSTMFCL-TCNFCL'den Çıkarılan Özniteliklere ve Seçilen Parametrelere Dayalı Doğruluk
Karar Ağacı	70,2% İnce Ağaç Maksimum Bölünme Sayısı: 100	77,5% İnce Ağaç Maksimum Bölünme Sayısı: 100	89,1% İnce Ağaç Maksimum Bölünme Sayısı: 100	91,8% İnce Ağaç Maksimum Bölünme Sayısı: 100
Ayırma Analizi	57,2% Doğrusal Ayırma	78,4% Karesel Ayırma	92,2% Doğrusal Ayırma	93,9% Doğrusal Ayırma
Naïve Bayes	59,1% Kernel Naïve Bayes Kernel Türü: Gauss	76,3% Kernel Naïve Bayes Kernel Türü: Gauss	91,2% Kernel Naïve Bayes Kernel Türü: Gauss	92,8% Gauss Naïve Bayes Sayısal Tahminciler için Dağıtım Adı: Gauss
SVM	82,4% Kernel Fonksiyonu: Karesel Çoklu Sınıf Yöntemi: Bire Karşı Bir	83,6% Kernel Fonksiyonu: Karesel Çoklu Sınıf Yöntemi: Bire Karşı Bir	93,6% Kernel Fonksiyonu: Kübik Çoklu Sınıf Yöntemi: Bire Karşı Bir	94,7% Kernel Fonksiyonu: Karesel Çoklu Sınıf Yöntemi: Bire Karşı Bir
KNN	77,9% k= 10 Öklid	79,8% k = 10 Öklid	92,5% k=10 Öklid	94,0% k=10 Öklid
Kolektif Öğrenme	79,6% Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30	80,5% Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30	93,0% Kolektif Yöntem: Alt Uzak Öğrenici Türü: En Yakın Komşular Öğrenici Sayısı: 30 Alt Uzak Boyutu: 6	94,2% Kolektif Yöntem: Torba Öğrenici Türü: Karar Ağacı Maksimum Bölünme Sayısı: 1279 Öğrenici Sayısı: 30

Gaz örneklerinden elde edilen veriler ile her bir konsantrasyon değeri arasındaki ilişki regresyon çalışması ile analiz edilerek tahmin sonuçlarının gerçek sonuçlara ne kadar yakın olduğu bulunmaya çalışılmıştır. Regresyonda, her bir gaz örneğinin konsantrasyon değerleri alınmış ve konsantrasyon değerlerinin tahmin analizinde başarı kriteri olarak MSE

kullanılmıştır. Öncelikle, ham verilere göre tahmin yapılmış ve MSE değerleri incelendiğinde her bir gaz için en yüksek MSE değerlerinin ham verilerle elde edildiği görülmüştür. Daha sonra, sensörlerden elde edilen verilerin maksimum değerleri öznitelik olarak seçilmiştir ve ham verilere göre daha iyi MSE değerleri elde edilmiştir. LSTM ağının tam bağlantılı katmanından çıkarılan öznitelikler kullanıldığında ise önerilen metodoloji ile tahmin analizinde hem ham verilere göre hem de maksimum değerlerin öznitelik olarak seçildiği çalışmaya göre daha düşük MSE değerleri elde edilmiştir. Son olarak ise LSTM ağının tam bağlantılı katmanından çıkarılan özniteliklerin TCN'ye giriş olarak verilmesi ve TCN'nin tam bağlantılı katmanından çıkarılan özniteliklerin kullanılması ile önerilen metodoloji ile diğer yöntemlere göre çok daha düşük MSE değerleri elde edilebilmiştir. Son önerilen metodoloji ile regresyon sonuçları daha da iyileştirilmiş ve bu metodoloji ile her bir gaz örneği için en iyi MSE değerlerinin elde edilmesi sağlanmıştır. Karbon monoksit için regresyon değerleri incelendiğinde, çalışmada önerilen son metodoloji ile en iyi MSE değerinin sinyal düzeltme uygulaması yapılan çalışmada 0,0129 ile GPR'de elde edildiği görülmektedir. Sinyal düzeltme uygulandığında ve uygulanmadığında, karbon monoksit için elde edilen regresyon değerleri Tablo 6.11 ve Tablo 6.12'de sırasıyla gösterilmektedir. Etanol için elde edilen regresyon değerleri incelendiğinde ise en iyi MSE değerine 0,0062 ile LSTM ve TCN'nin birlikte kullanıldığı yöntemle GPR'de ulaşıldığı görülmektedir. Etanolde de yine en iyi sonuç geliştirilen son yöntemle ve sinyal düzeltme uygulanarak elde edilmiştir. Tablo 6.13 ve Tablo 6.14'te etanol için regresyon değerleri verilmektedir. Etilen için elde edilen regresyon değerleri, sinyal düzeltme uygulanması ve uygulanmaması durumuna göre Tablo 6.15 ve Tablo 6.16'da gösterilmektedir. Buna göre etilen için en iyi sonuç sinyal düzeltme uygulanarak LSTMFCL-TCNFCL ile 0.0044 olarak elde edilmiştir. Tablo 6.17 ve Tablo 6.18 incelendiğinde ise, metan gazı için elde edilen regresyon sonuçlarına göre en iyi MSE değerine yine LSTM ve TCN'nin birlikte kullanılarak özniteliklerin çıkarıldığı yöntem ile ulaşıldığı görülmektedir. Metan için en düşük MSE değeri 0,0022 ile GPR algoritmasında elde edilmiştir ve burada da sinyal düzeltme uygulandığında, sinyal düzeltme uygulanmamasına göre daha iyi sonuçlar elde edildiği görülmektedir. Tahmin sonuçları, gerçek sonuçlarla iyi bir tutarlılık göstermektedir ve hatalar küçüktür.

Tablo 6.11. Karbon monoksit için sinyal düzeltme uygulanmadığı zaman elde edilen regresyon değerleri.

Karbon Monoksit	Ham Verilere Göre MSE	Maksimum Değerlere Göre MSE	LSTM'nin Tam Bağlantılı Katmanından Elde Edilen Verilere Göre MSE	LSTMFCL - TCNFCL Modelinden Elde Edilen Verilere Göre MSE
Doğrusal SVR	0,3224	0,3611	0,1373	0,0819
Ağaç Regresyonu	0,4811	0,4615	0,3741	0,2645
Topluluk Öğrenmesi Regresyonu	0,4680	0,4028	0,3834	0,2712
Gauss Süreci Regresyonu	0,0840	0,2473	<u>0,0631</u>	<u>0,0565</u>
Doğrusal Regresyon	0,9638	0,6944	0,6490	0,4058

Tablo 6.12. Karbon monoksit için sinyal düzeltme uygulandığı zaman elde edilen regresyon değerleri.

Karbon Monoksit	Ham Verilere Göre MSE	Maksimum Değerlere Göre MSE	LSTM'nin Tam Bağlı Katmanından Elde Edilen Verilere Göre MSE	LSTMFCL için SC Kullanıldığında Hata Azalma Oranı	LSTMFCL - TCNFCL Modelinden Elde Edilen Verilere Göre MSE	LSTMFCL - TCNFCL için SC Kullanıldığında Hata Azalma Oranı	LSTMFCL'ye Göre LSTMFCL – TCNFCL'deki Hata Azalma Oranı
Doğrusal SVR	0,2829	0,3256	0,0181	87%	0,0151	82%	17%
Ağaç Regresyonu	0,3728	0,3451	0,0318	92%	0,0221	92%	31%
Topluluk Öğrenmesi Regresyonu	0,3621	0,3374	0,0296	92%	0,0214	92%	28%
Gauss Süreci Regresyonu	0,0824	0,2312	<u>0,0145</u>	77%	<u>0,0129</u>	77%	11%
Doğrusal Regresyon	0,6320	0,5426	0,0289	96%	0,0161	96%	44%

Tablo 6.13. Etanol için sinyal düzeltme uygulanmadığı zaman elde edilen regresyon değerleri.

Etanol	Ham Verilere Göre MSE	Maksimum Değerlere Göre MSE	LSTM'nin Tam Bağılantılı Katmanından Elde Edilen Verilere Göre MSE	LSTMFCL - TCNFCL Modelinden Elde Edilen Verilere Göre MSE
Doğrusal SVR	0,3171	0,1581	0,0274	0,0218
Ağaç Regresyonu	0,2472	0,2013	0,0434	0,0314
Topluluk Öğrenmesi Regresyonu	0,1893	0,1881	0,0464	0,0342
Gauss Süreci Regresyonu	0,0818	0,0930	<u>0,0242</u>	<u>0,0214</u>
Doğrusal Regresyon	0,8909	0,6476	0,0352	0,0220

Tablo 6.14. Etanol için sinyal düzeltme uygulandığı zaman elde edilen regresyon değerleri.

Etanol	Ham Verilere Göre MSE	Maksimum Değerlere Göre MSE	LSTM'nin Tam Bağlı Katmanından Elde Edilen Verilere Göre MSE	LSTMFCL için SC Kullanıldığında Hata Azalma Oranı	LSTMFCL - TCNFCL Modelinden Elde Edilen Verilere Göre MSE	LSTMFCL - TCNFCL için SC Kullanıldığında Hata Azalma Oranı	LSTMFCL'ye Göre LSTMFCL – TCNFCL'deki Hata Azalma Oranı
Doğrusal SVR	0,2082	0,1408	0,0100	64%	0,0084	62%	16%
Ağaç Regresyonu	0,2102	0,1670	0,0166	62%	0,0117	63%	30%
Topluluk Öğrenmesi Regresyonu	0,1728	0,1626	0,0159	66%	0,0106	69%	33%
Gauss Süreci Regresyonu	0,0746	0,0872	<u>0,0071</u>	71%	<u>0,0062</u>	71%	13%
Doğrusal Regresyon	0,4765	0,3561	0,0150	57%	0,0087	61%	42%

Tablo 6.15. Etilen için sinyal düzeltme uygulanmadığı zaman elde edilen regresyon değerleri.

Etilen	Ham Verilere Göre MSE	Maksimum Değerlere Göre MSE	LSTM'nin Tam Bağlantılı Katmanından Elde Edilen Verilere Göre MSE	LSTMFCL - TCNFCL Modelinden Elde Edilen Verilere Göre MSE
Doğrusal SVR	0,2701	0,2371	0,0197	0,0148
Ağaç Regresyonu	0,3393	0,2411	0,0395	0,0277
Topluluk Öğrenmesi Regresyonu	0,3326	0,2165	0,0462	0,0338
Gauss Süreci Regresyonu	0,0231	0,1080	<u>0,0146</u>	<u>0,0120</u>
Doğrusal Regresyon	0,6983	0,6007	0,0239	0,0151

Tablo 6.16. Etilen için sinyal düzeltme uygulandığı zaman elde edilen regresyon değerleri.

Etilen	Ham Verilere Göre MSE	Maksimum Değerlere Göre MSE	LSTM'nin Tam Bağlı Katmanından Elde Edilen Verilere Göre MSE	LSTMFCL için SC Kullanıldığında Hata Azalma Oranı	LSTMFCL - TCNFCL Modelinden Elde Edilen Verilere Göre MSE	LSTMFCL - TCNFCL için SC Kullanıldığında Hata Azalma Oranı	LSTMFCL'ye Göre LSTMFCL – TCNFCL'deki Hata Azalma Oranı
Doğrusal SVR	0,2300	0,2237	0,0075	62%	0,0054	64%	28%
Ağaç Regresyonu	0,2697	0,1920	0,0106	73%	0,0072	74%	32%
Topluluk Öğrenmesi Regresyonu	0,2376	0,1846	0,0098	79%	0,0068	80%	31%
Gauss Süreci Regresyonu	0,0224	0,1018	<u>0,0055</u>	62%	<u>0,0044</u>	63%	20%
Doğrusal Regresyon	0,3412	0,3856	0,0093	61%	0,0056	63%	40%

Tablo 6.17. Metan için sinyal düzeltme uygulanmadığı zaman elde edilen regresyon değerleri.

Metan	Ham Verilere Göre MSE	Maksimum Değerlere Göre MSE	LSTM'nin Tam Bağlantılı Katmanından Elde Edilen Verilere Göre MSE	LSTMFCL - TCNFCL Modelinden Elde Edilen Verilere Göre MSE
Doğrusal SVR	0,8851	0,0787	0,0412	0,0306
Ağaç Regresyonu	0,2147	0,1071	0,0475	0,0322
Topluluk Öğrenmesi Regresyonu	0,2401	0,1127	0,0492	0,0344
Gauss Süreci Regresyonu	0,0919	0,0426	<u>0,0275</u>	<u>0,0232</u>
Doğrusal Regresyon	0,8906	0,6317	0,0446	0,0269

Tablo 6.18. Metan için sinyal düzeltme uygulandığı zaman elde edilen regresyon değerleri.

Metan	Ham Verilere Göre MSE	Maksimum Değerlere Göre MSE	LSTM'nin Tam Bağlı Katmanından Elde Edilen Verilere Göre MSE	LSTMFCL için SC Kullanıldığında Hata Azalma Oranı	LSTMFCL - TCNFCL Modelinden Elde Edilen Verilere Göre MSE	LSTMFCL - TCNFCL için SC Kullanıldığında Hata Azalma Oranı	LSTMFCL'ye Göre LSTMFCL – TCNFCL'deki Hata Azalma Oranı
Doğrusal SVR	0,1436	0,0721	0,0049	88%	0,0035	89%	29%
Ağaç Regresyonu	0,1624	0,0829	0,0102	79%	0,0068	79%	33%
Topluluk Öğrenmesi Regresyonu	0,1582	0,0804	0,0094	81%	0,0064	81%	32%
Gauss Süreci Regresyonu	0,0566	0,0376	<u>0,0027</u>	90%	<u>0,0022</u>	91%	19%
Doğrusal Regresyon	0,2634	0,2595	0,0070	84%	0,0037	86%	47%

GPR algoritması, kendisini analitik yollarla hesaplayamadığımız fonksiyonlar için tahmin yapmak amaçlı kullanılmaktadır. Gauss Süreç Regresyon yaklaşımı yüksek boyutlar, doğrusal olmama gibi karmaşık regresyon problemlerinin çözümünde kullanıma uygun, parametrik olmayan bir yaklaşımdır ve güçlü genelleme yeteneğine sahiptir. Parametrelerin kullanımı yerine gözlemlerle tutarlı olan olası tüm fonksiyonlar üzerinde bir dağılım bulmamıza yardımcı olur. Gauss süreci, Gauss olasılık dağılımının bir genellemesidir ve sonsuz boyuttadır. Özellikle büyük boyutlu fonksiyonel verilerle uğraşırken, model yapısını yorumlama, model öğrenme ve çıkarım gerçekleştirme konusunda verimli yollar sağlamaktadır. GPR, gaz konsantrasyonunun tahmini gibi doğrusal olmayan regresyon problemlerinin çözümünde kullanılmaya uygundur. Tahmin yapmak için ortalama ve kovaryans fonksiyonlarını kullanır ve bu fonksiyonların seçimi, düzgünlük varsayımlarını uygular. Bu nedenlerden dolayı, çalışmamızda kullanılan gaz verileri için GPR algoritması ile başarılı sonuçlar elde edilmiştir.

Tablo 6.19. Karbon monoksit, etanol, etilen ve metan gazları için elde edilen en iyi regresyon değerleri.

	Karbon Monoksit	Etanol	Etilen	Metan
Gauss Süreci Regresyonu	<u>0,0129</u>	<u>0,0062</u>	<u>0,0044</u>	<u>0.0022</u>

Tezde kullanılan veri seti için literatürdeki diğer çalışmalarda incelenmiştir. Buna göre: [175]'te yükselen pencere protokolüne ve ham sinyallerin erken bir bölümünün işlenmesine dayalı olarak hızlı algılama yaklaşımını doğrulamak için üç farklı DL algoritması ve bir Destek Vektör Makinesi (SVM) yöntemi kullanılmıştır. Ölçüm verilerinin ilk 30%'u veya daha azı kullanılarak güvenilir tahminler elde edilmiştir. Birinci pencere (w1) bilgilerin ilk 10%'una karşılık gelmektedir, ikinci pencere (w2) ölçüm verilerinin 20%'sini içermektedir ve ölçüm verilerinin 100%'ünü içeren onuncu pencereye (w10) kadar devam etmektedir. SVM algoritmasıyla diğer yöntemlere göre daha fazla yüksek doğruluk oranları elde edilmiştir. Bu çalışmayla, ölçüm verilerinin küçük bir bölümüyle de güvenilir tahminler yapılabildiği ve eğitim süresinin azaltılabildiği gösterilmiştir. Bununla birlikte, referans makalesinde verilerin hepsi kullanıldığı zaman DL algoritmaları ile elde edilen doğruluklar genel olarak verilerin ilk 30%'u veya daha azı kullanılarak elde edilen doğruluklardan daha az başarı göstermiştir.

[176]'da sınıflandırma doğruluğunu ve ölçüm hızını iyileştirmek için sensör dizisinin zaman içindeki enerji değişimini çıkaran, daha sonra ise enerji değişimine dayalı olarak hızlı gaz tespitinde hangi zaman periyodunun daha elverişli olduğunu belirlemek için sınıflandırma modellerini birleştiren yeni bir algoritma önerilmiştir. Ölçüm hızını arttırmak için sensörlerin veri toplama süresi azaltılmıştır. Bunun içinde gaz tanımasında kullanılan sensörlerin orijinal örnekleme noktaları azaltılmıştır. Önerilen algoritma ile ölçüm verilerinin ortalama olarak ilk 23,68%'i kullanılarak ölçüm süresi azaltılmış ve yüksek sınıflandırma doğruluğu elde edilmiştir.

[177]'de gaz tanıma için hafif DNN modellerinin sınıflandırma performansını iyileştirmek için CL tabanlı üç yaklaşım önerilmiştir: Alan bilgisi, örneklerin yanıtları arasındaki korelasyon gücü ve çoklu öğretmen modellerinden sınıflandırma zorluğu ve anlaşmazlık. Bu yaklaşımların uygulanmasıyla da veri setindeki çeşitli DNN modellerinin

gaz sınıflandırma doğruluğu ve F1 puanı sırasıyla ortalama 9,9% ve 10,9% oranında iyileşmiştir.

Bu çalışmaların üçünde de gaz verileri 4 sınıfa ayrılarak gaz tipi tespit edilmiştir. 5 bağımsız kimyasal tespit ünitesi için ayrı ayrı sınıflandırma işlemleri gerçekleştirilmiştir. Tezde ise konsantrasyon değerlerine göre bir sınıflandırma işlemi yapılarak veri setindeki ölçümler 12 sınıfa ayrılmıştır ve tüm veri seti kullanılarak sınıflandırma ve tahmin işlemleri gerçekleştirilmiştir.

[178]'de sensör kayması probleminin çözümünde geleneksel yöntemler yerine hedef alandan seçilen az sayıda etiketli örneği kullanarak düşük boyutlu bir ayırt edici alt uzayı ve güçlü bir sınıflandırıcıyı öğrenen etki alanları arası öznitelik alt uzay transfer öğreniminden ve etki alanları arası adaptasyon aşırı öğrenme makinesinden (CFST-AELM) oluşan bir yöntem kullanılmıştır. Alan uyarlamalı öğrenme ve transfer öğrenmeden esinlenerek, öznitelik düzeyinde etki alanı hizalama ve ön dağıtım ayarlaması yapılmıştır, bununla birlikte aktarım örnekleri aracılığıyla daha iyi tahmin performansın gerçekleştirilmesi adına karar düzeyinde etki alanları arası uyarlanabilir bilgi aktarımı gerçekleştirilmiştir. Öncelikle, Replika 1 kaynak alan olarak sabitlenmiştir ve Replika K ($K=2,3,4,5$) hedef alan olarak sırayla test edilmiştir. Daha sonra ise Replika 5 kaynak etki alanı olarak sabitlenmiştir ve Replika K ($K=1,2,3,4$) sırayla hedef etki alanı olarak test edilmiştir. Sonuçlar, sınıflandırma doğruluğu açısından birkaç yöntemle karşılaştırıldığında, CFST-AELM yönteminin diğerlerine göre daha üstün performansa sahip olduğunu göstermektedir. Bu çalışmada da gaz tipine göre sonuçlar elde edilmiştir ve ölçüm verileri 4 sınıfa ayrılmıştır.

[167]'de, sensör kayması problemi, standardizasyon yöntemleri kullanılarak kalibrasyonla incelenmiştir. Buna göre aynı ünite ve farklı üniteler arasındaki sensör değişkenliği, cihazlar arasındaki kalibrasyon transferi ve aynı cihaz içindeki kalibrasyon transferi için tahmin hataları incelenmiştir. Tezde ise kalibrasyon düzeltme yöntemleri kullanmadan gazların konsantrasyon seviyesine göre sınıflandırılması ve regresyonu üzerine bir çalışma gerçekleştirilmiştir.

7. SONUÇ

Bu çalışmada, 10 farklı konsantrasyon seviyesinde olan etanol, metan, etilen ve karbon monoksit gazlarının sınıflandırılması ve konsantrasyon değerlerinin tahmin edilmesi için 4 metal oksit gaz sensörü kullanılarak geliştirilen elektronik burundan elde edilen 640 farklı veriye sınıflandırma ve regresyon başarısının artırılması için farklı yöntemler uygulanmıştır. Bu amaçla, örüntü tanımda sinyal ön işleme, öznitelik çıkarma ve sınıflandırma aşamaları gerçekleştirilmiştir. Öznitelik çıkarma aşamasında ise LSTM ağının tam bağlantılı katmanından çıkarılan öznitelikler TCN'ye giriş olarak verilmiştir ve TCN'nin tam bağlantılı katmanı kullanılarak faydalı bilgilerin çıkarılması için bir yöntem geliştirilmiştir. Çıkarılan öznitelikler, sınıflandırma aşamasında Karar Ağacı, Doğrusal ve Karesel Ayırma Analizi, Naïve Bayes, SVM, KNN ve Kolektif Öğrenme sınıflandırma algoritmalarında kullanılırken regresyon aşamasında ise Doğrusal Destek Vektör Regresyonu, Karar Ağacı Regresyonu, Kolektif Öğrenme Regresyonu, Gauss Süreci Regresyonu ve Doğrusal Regresyon algoritmalarında kullanılmıştır. Önerilen yöntemler bugüne kadar e-burun çalışmalarında farklı gaz türlerinin konsantrasyon değerlerinin sınıflandırılmasında ve regresyonunda uygulanmamıştır.

Çoklu öznitelik seviyelerini veya verilerin temsillerini öğrenmeye dayanan makinelerin yapay zekâ yaklaşımlarından biri olan derin öğrenme ağları kullanılarak geliştirilen bu yöntemlerin hem sınıflandırma hem de regresyon sonuçlarında kullanılmasıyla diğer öznitelik çıkarma yöntemlerine göre yüksek doğruluk elde edilmiştir. Sınıflandırma aşamasında en yüksek doğruluk oranları ham verilere göre 82,4%, öznitelik olarak sensörlerden elde edilen verilerin maksimum değerleri kullanıldığında 83,6%, önerilen yöntemlerden biri olan LSTM ağının tam bağlantılı katmanından elde edilen veriler öznitelik olarak kullanıldığında ise 93,6% ile SVM algoritmasında elde edilmiştir. Önerilen ikinci yöntemle SVM'de elde edilen başarı oranı ise 94,7%'dir. Regresyon aşamasında, LSTM ağının tam bağlantılı katmanından öznitelik çıkarımı gerçekleştirildiği zaman, GPR algoritmasında elde edilen MSE değerleri karbon monoksitte 0,0145, etanolde 0,0071, etilende 0,0055, metanda 0,0027'dir. Önerilen ikinci yöntemle ise, GPR'deki en düşük ortalama karesel hatalar karbon monoksitte 0,0129, etanolde 0,0062, etilende 0,0044, metanda 0,0022 olarak elde edilmiştir. Derin öğrenme bir yapay zekâ algoritmasıdır ve doğrusal olmayan kestirimlerde dikkate değer avantajlar sağlar. Sonuçlardan da görüldüğü üzere önerilen yöntemlerle hem sınıflandırma hem de regresyonda daha yüksek başarılar elde edilmiştir. Deneysel sonuçlar da bu iddiayı doğrulamaya hizmet etmektedir. Elde edilen

doğruluk bazında diğer sonuçlara kıyasla, önerilen yöntemlerin etkinliğinin yüksek olduğu kanıtlanmıştır. LSTM ağlarının yanı sıra TCN derin öğrenme ağlarının da zaman serisi verilerinin ayırt edilmesinde kullanılabildiği gaz sensörü verilerinden ayırt edici özelliklerin ortaya çıkarılmasıyla doğrulanmaktadır.

Öznitelik çıkarma aşamasında ise geliştirilen ikinci yöntemde, LSTM ağı ve TCN birleştirilerek modelleme ve tahmin sonuçlarında iyileştirmeye gidilmiştir. Evrişimsel sinir ağları, temel olarak görüntüleri sınıflandırmak, benzerlikleri kümelemek ve nesne tanıma yapmak için kullanılan derin yapay sinir ağlarıdır. Bununla birlikte, evrişimsel sinir ağları tek boyutlu sensör verilerinin sınıflandırılması ve regresyonu için de kullanılabilmektedir. LSTM'nin çıkışları, TCN'nin yapısına şekil bazında çok uygun olduğu için böyle bir model oluşturulmuştur. Bu nedenle, LSTM'nin tam bağlantılı katmanından elde edilen öznitelikler, sınıflandırma ve regresyonda TCN ile yeniden öznitelğe sokulmuştur. Buna ek olarak, evrişimsel sinir ağlarının, tipik dizi modelleme görevlerinde tekrarlayan ağların performansı ile eşleşebileceği de gösterilmektedir. Önerilen yöntemler, şimdiye kadar elektronik burun çalışmalarında farklı gaz türlerinin konsantrasyon değerlerinin sınıflandırılması ve regresyonunda uygulanmamıştır.

Gelecekteki çalışmalar için bu yöntem farklı LSTM ve TCN yapıları kullanılarak ya da RNN, RBM, Gürültü Giderici Özkodlayıcı Ağlar (*Denoising Autoencoders, DAE*), Derin İnanç Ağları (*Deep Belief Networks, DBN*) gibi farklı derin sinir ağları kullanılarak, ağ yapıları optimize edilerek geliştirilebilir, model doğruluğu ve tahmin sonuçlarında iyileştirme gerçekleştirilebilir. Ayrıca Elektronik Burun uygulamalarında, veri sayısı genelde derin öğrenme yöntemleri için az olduğundan yine derin öğrenme yöntemleri kullanılarak veri çoğaltmanın başarı üzerindeki etkileri incelenebilir. Olumlu etkileri olması durumunda deneysel olarak zaman kazandıran veri çoğaltmanın literatüre oldukça katkı sağlayabileceği düşünülmektedir.

KAYNAKLAR

- [1] K. Arshak, E. Moore, G. M. Lyons, J. Harris, and S. Clifford, "A review of gas sensors employed in electronic nose applications," *Sens. Rev.*, vol. 24, no. 2, pp. 181–198, 2004, doi: 10.1108/02602280410525977.
- [2] M. T. Kalit, K. Marković, S. Kalit, N. Vahčić, and J. Havranek, "Application of electronic nose and electronic tongue in the dairy industry," *Mljekarstvo*, vol. 64, no. 4, pp. 228-244, 2014, doi: 10.15567/mljekarstvo.2014.0402.
- [3] E. H. Oh, H. S. Song, and T. H. Park, "Recent advances in electronic and bioelectronic noses and their biomedical applications," *Enzyme Microb. Technol.*, vol. 48, pp. 427-437, 2011, doi: 10.1016/j.enzmictec.2011.04.003.
- [4] W. Miekisch, J. K. Schubert, and G. F. E Noeldge-Schomburg, "Diagnostic potential of breath analysis—focus on volatile organic compounds," *Clin. Chim. Acta*, vol. 347, pp. 25-39, 2004, doi: 10.1016/j.cccn.2004.04.023.
- [5] B. H. Tozlu, C. Şimşek, O. Aydemir, and Y. Karavelioglu, "A High performance electronic nose system for the recognition of myocardial infarction and coronary artery diseases," *Biomed. Signal Process. Control*, vol. 64, 102247, 2021, doi: 10.1016/j.bspc.2020.102247.
- [6] M. Phillips, R. N. Cataneo, B. A. Ditkoff, P. Fisher, J. Greenberg, R. Gunawardena, et al. "Prediction of breast cancer using volatile biomarkers in the breath," *Breast Cancer Res. Treat.*, vol. 99, pp. 19-21, 2006, doi: 10.1007/s10549-006-9176-1.
- [7] A. K. Pavlou, N. Magan, C. McNulty, J. M. Jones, D. Sharp, J. Brown, et al. "Use of an electronic nose system for diagnoses of urinary tract infections," *Biosens. Bioelectron.*, vol. 17, no. 10, pp. 893-899, 2002, doi: 10.1016/s0956-5663(02)00078-7.
- [8] R. F. Machado, D. Laskowski, O. Deffenderfer, T. Burch, S. Zheng, P. J. Mazzone, et al. "Detection of lung cancer by sensor array analyses of exhaled breath," *Am. J. Respir.*

- Crit. Care Med.*, vol. 171, no. 11, pp. 1286-1291, 2005, doi: 10.1164/rccm.200409-1184OC.
- [9] J. W. Gardner and P. N. Bartlett, "A brief history of electronic noses," *Sensor. Actuator. B: Chem.*, vol. 18, pp. 210–211, 1994, doi: 10.1016/0925-4005(94)87085-3.
- [10] S. Güney and A. Atasoy, "Multiclass classification of n-butanol concentrations with k nearest neighbor algorithm and support vector machine in an electronic nose," *Sensor. Actuator. B: Chem.*, vol. 166–167, pp. 721–725, 2012, doi: 10.1016/j.snb.2012.03.047.
- [11] Y. Zou, H. Wan, X. Zhang, D. Ha, and P. Wang, "Electronic nose and electronic tongue," in *Bioinspired Smell and Taste Sensors*, P. Wang, Q. Liu, C. Wu, K. Hsia, Ed., Springer, Dordrecht, pp. 19-44, 2015, doi: 10.1007/978-94-017-7333-1_2.
- [12] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436–444, 2015 doi: 10.1038/nature14539.
- [13] P. Peng, X. Zhao, X. Pan, and W. Ye, "Gas classification using deep convolutional neural networks," *Sensors.*, vol. 18, no. 1: 157, 2018, doi: 10.3390/s18010157.
- [14] Q. Wang, T. Xie, and S. Wang, "Research on air pollution gases recognition method based on LSTM recurrent neural network and gas sensors array," in *Proceedings of the 2018 Chinese Automation Congress (CAC)*, Xi'an, China, pp. 3486-3491, 2018, doi: 10.1109/CAC.2018.8623060.
- [15] H. Liu, Q. Li, and Y. Gu, "A multi-task learning framework for gas detection and concentration estimation," *Neurocomputing*, vol. 416, pp. 28–37, 2020, doi: 10.1016/j.neucom.2020.01.051.
- [16] P. Narkhede, R. Walambe, S. Mandaokar, P. Chandel, K. Kotecha, and G. Ghinea, "Gas detection and identification using multimodal artificial intelligence based sensor fusion," *Appl. Syst. Innov.*, vol. 4, no. 3, 2021, doi: 10.3390/asi4010003.
- [17] G. F. Wei, G. Li, J. Zhao, and A. X. He, "Development of a LeNet-5 gas identification CNN structure for electronic noses," *Sensors.*, vol. 19, no. 1, p. 217, 2019, doi: 10.3390/s19010217.

- [18] H. E. Zhang, W. B. Ye, X. J. Zhao, R. K. F. Teng, and X. F. Pan, "A novel convolutional recurrent neural network-based algorithm for fast gas recognition in electronic nose system," in *Proceedings of IEEE International Conference on Electron Devices and Solid-State Circuits (EDSSC)*, IEEE, Shenzhen, China, 2018, doi: 10.1109/EDSSC.2018.8487105.
- [19] C. T. Tang, C. M. Huang, K. T. Tang, and H. Chen, "A scalable and adaptable probabilistic model embedded in an electronic nose for intelligent sensor fusion," in *Proceedings of IEEE Biomedical Circuits and Systems Conference (BioCAS)*, Atlanta, USA, 2015, doi: 10.1109/BioCAS.2015.7348377.
- [20] P. F. Qi, Q. H. Meng, and M. Zeng, "A CNN-based simplified data processing method for electronic noses," in *Proceedings of ISOCS/IEEE International Symposium on Olfaction and Electronic Nose*, IEEE, Montreal, Canada, pp. 1–3, 2017, doi: 10.1109/ISOEN.2017.7968887.
- [21] M. Langkvist and A. Loutfi, "Unsupervised feature learning for electronic nose data applied to Bacteria Identification in Blood," in *Proceedings of the NIPS 2011 Workshop on Deep Learning and Unsupervised Feature Learning*, Granada, Spain, 2011, pp. 1–7.
- [22] J. C. Rodriguez Gamboa, A. J. da Silva, I. C. S. Araujo, E. S. Albarracin E., and C. M. Duran A., "Validation of the rapid detection approach for enhancing the electronic nose systems performance, using different deep learning models and support vector machines," *Sensor. Actuator. B: Chem.*, vol. 327, 128921, 2021 doi:10.1016/j.snb.2020.128921.
- [23] J. Wang, J. Ji, A. P. Ravikumar, S. Savarese, and R. B. Adam, "VideoGasNet: Deep learning for natural gas methane leak classification using an infrared camera," *Energy*, vol. 238, 121516, 2022, doi: 10.1016/j.energy.2021.121516.
- [24] S. Y. Park, B. Son, J. Choi, H. Jin, and K. Lee, "Application of machine learning to quantification of mineral composition on gas hydrate-bearing sediments," Ulleung Basin, Korea, *J. Pet. Sci. Eng.*, vol. 209, 109840, 2022, doi: 10.1016/j.petrol.2021.109840.
- [25] Y. -Y. Liu, X. -H. Ma, X. -W. Zhang, W. Guo, L. -X. Kang, R. -Z. Yu, and Y. -P. Sun, "A deep-learning-based prediction method of the estimated ultimate recovery (EUR) of

shale gas wells,” *Pet. Sci.*, vol. 18, pp. 1450-1464, 2021 doi: 10.1016/j.petsci.2021.08.007.

- [26] M. Barriault, I. Alexander, N. Tasnim, A. O’Brien, H. Najjaran, and M. Hoorfar, “Classification and regression of binary hydrocarbon mixtures using single metal oxide semiconductor sensor with application to natural gas detection,” *Sensor. Actuator. B: Chem.*, vol. 326, 129012, 2021, doi: 10.1016/j.snb.2020.129012.
- [27] J. Torres-Tello, A. V. Guaman, and S. -B. Ko, “Improving the Detection of Explosives in a MOX Chemical Sensors Array with LSTM Networks,” *IEEE Sens. J.*, vol. 20, no. 23, pp. 14302-14309, 2020, doi: 10.1109/JSEN.2020.3007431.
- [28] D. Zhou, Q. Yao, H. Wu, S. Ma, and H. Zhang, “Fault diagnosis of gas turbine based on partly interpretable convolutional neural networks,” *Energy*, vol. 200, 117467, 2020, doi: 10.1016/j.energy.2020.117467.
- [29] N. Jin, Y. Zeng, K. Yan, and Z. Ji, “Multivariate air quality forecasting with nested long short-term memory neural network,” *IEEE Trans. Industr. Inform.*, vol. 17, pp. 8514-8522, 2021, doi: 10.1109/TII.2021.3065425.
- [30] L. Han, C. Yu, K. Xiao, and X. Zhao, “A new method of mixed gas identification based on a convolutional neural network for time series Classification,” *Sensors.*, vol. 19, 1960, 2019, doi: 10.3390/s19091960.
- [31] S. Benedetti, C. Pompei, and S. Mannino, “Comparison of an electronic nose with the sensory evaluation of food products by Triangle Test,” *Electroanalysis*, vol. 16, no. 21, pp. 1801-1805, 2004, doi: 10.1002/elan.200303036.
- [32] S. Güney, “Karma yapılı ikili karar ağacı tabanlı koku tanıma sistemi,” Doktora Tezi, Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi, Trabzon, 2013.
- [33] M. Peris and L. Escuder-Gilabert, “Electronic noses and tongues to assess food authenticity and adulteration,” *Trends Food Sci. Technol.*, vol. 58, pp. 40-54, 2016 doi: 10.1016/j.tifs.2016.10.014.
- [34] A. T. Güntner, V. Koren, K. Chikkadi, M. Righettoni, and S. Pratsinis, “E-nose sensing of low-ppb formaldehyde in gas mixtures at high relative humidity for breath screening

- of lung cancer?”, *ACS Sensors*, vol. 1, no. 5, pp. 528-535, 2016, doi: 10.1021/acssensors.6b00008.
- [35] J. Chilo, J. Pelegri-Sebastia, M. Cupane, and T. Sogorb, “E-nose application to food industry production,” *IEEE Instrum. Meas. Mag.*, vol. 19, no. 1, pp. 27-33, 2016, doi: 10.1109/MIM.2016.7384957.
- [36] L. Capelli, S. Sironi, and R. Del Rosso, “Electronic noses for environmental monitoring applications,” *Sensors*, vol. 14, no. 11, pp. 19979-20007, 2014, doi: 10.3390/s141119979.
- [37] A. D. Wilson and M. Baietto, “Applications and Advances in Electronic-Nose Technologies,” *Sensors*, vol. 9, no. 7, pp. 5099–5148, 2009, doi: 10.3390/s90705099.
- [38] N. Tamaekong, C. Liewhiran, A. Wisitsoraat, and S. Phanichphant, “Flame-spray-made undoped zinc oxide films for gas sensing applications,” *Sensors*, vol. 10, no. 8, pp. 7863-7873, 2010, doi: 10.3390/s100807863.
- [39] R. Blatt, A. Bonarini, and M. Matteucci, “Pattern classification techniques for lung cancer diagnosis by an electronic nose,” *Studies in Computational Intelligence*, vol. 309, 2010, doi: 10.1007/978-3-642-14464-6_18.
- [40] J. W. Gardner, H. W. Shin, and E. L. Hines, “An electronic nose system to diagnose illness,” *Sensor. Actuator. B: Chem.*, vol. 70, pp. 19-24, 2000, doi: 10.1016/S0925-4005(00)00548-7.
- [41] S. Chen, Y. Wang, and S. Choi, “Applications and technology of electronic nose for clinical diagnosis,” *Journal of Applied Biosensor.*, vol. 2, 2013, doi: 10.4236/ojab.2013.22005.
- [42] A. O. Selvi, “İnsan nefesinden kandaki glikoz ve HbA1c değerlerinin elektronik burun kullanılarak belirlenmesi,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Dumlupınar Üniversitesi, Kütahya, 2010.
- [43] Ö. B. Yurdakoş , “Detection of degradation levels in food industry by using e-nose sensors,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Dokuz Eylül Üniversitesi, İzmir, 2019.

- [44] R. Castro, M. K. Mandal, P. Ajemba, and M. A. Istihad, "An electronic nose for multimedia applications," in *IEEE Transactions on Consumer Electronics*, vol. 49, no. 4, pp. 1431-1437, 2003, doi: 10.1109/TCE.2003.1261251.
- [45] J. Tan and J. Xu, "Applications of electronic nose (e-nose) and electronic tongue (e-tongue) in food quality-related properties determination: A review," *Artif. Intell. Agric.*, vol. 4, pp. 104-115, 2020, doi: 10.1016/j.aiia.2020.06.003.
- [46] J. Jońca, M. Pawnuk, A. Arsen, and I. Sówka, "Electronic noses and their applications for sensory and analytical measurements in the waste management plants-a review," *Sensors.*, vol. 22, 1510, 2022, doi: 10.3390/s22041510.
- [47] L. Ghorbanı, "Implementation of KNN, MLP, PCA algorithms on Cortex-M4 based embedded system for e-nose application," Yüksek Lisans Tezi, Fen Mühendisliği ve Teknoloji Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2014.
- [48] L. Capelli, G. Taverna, A. Bellini, L. Eusebio, N. Buffi, M. Lazzeri, G. Guazzoni, G. Bozzini, M. Seveso, A. Mandressi, L. Tidu, F. Grizzi, P. Sardella, G. Latorre, R. Hurle, G. Lughezzani, P. Casale, S. Meregali, and S. Sironi, "Application and uses of electronic noses for clinical diagnosis on urine samples: A review," *Sensors*, vol. 16, pp. 1-23, 2016, doi: 10.3390/s16101708.
- [49] M. Cosio, S. Benedetti, S. Buratti, M. Scampicchio, and S. Mannino, Chapter 60 – "Application of the electronic nose in olive oil analyses," in *Olives and Olive Oil in Health and Disease Prevention*, V. R. Preedy and R. R. Watson, Ed., Academic Press, 2010, pp. 553-559, doi: 10.1016/B978-0-12-374420-3.00060-7.
- [50] T. D. Gibson, O. Prosser, J. N. Hulbert, R. W. Marshall, P. Corcoran, P. Lowery, E. A. Ruck-Keene, and S. Heron, "Detection and simultaneous identification of microorganisms from headspace samples using an electronic nose," *Sensor. Actuator. B: Chem.*, vol. 44, pp. 413-422, 1997, doi: 10.1016/S0925-4005(97)00235-9.
- [51] D. Li, T. Lei, S. Zhang, X. Shao, and C. Xie, "A novel headspace integrated e-nose and its application in discrimination of Chinese medical herbs," *Sensor. Actuator. B: Chem.*, vol. 221, pp. 556–563, 2015, doi: 10.1016/j.snb.2015.06.144.

- [52] H. R. Estakhoyeh, E. Rashedi, and M. Mehran, "Design and construction of electronic nose for multi-purpose applications by sensor array arrangement using IBGSA," *J Intell Robot Syst*, vol. 92, pp. 205-221, 2018, doi:10.1007/s10846-017-0759-3.
- [53] R. Ionescu, Y. Broza, H. Shaltieli, D. Sadeh, Y. Zilberman, X. Feng, et al., "Detection of multiple sclerosis from exhaled breath using bilayers of polycyclic aromatic hydrocarbons and single-wall carbon nanotubes," *ACS Chem. Neurosci.*, vol. 2, no. 12, pp. 687– 693, 2011, doi: 10.1021/cn2000603.
- [54] E. Schaller, J. O. Bosset, and F. Escher, "Electronic noses', and their application to food," *Lebensm. -Wiss. u.-Technol.*, vol. 31, pp. 305–316, 1998, doi: 10.1006/fstl.1998.0376.
- [55] H. T. Nagle, R. Gutierrez-Osuna, and S. Schiffman, "The how and why of electronic noses," *IEEE Spectrum*, vol. 35, no. 9, pp. 22 – 31, 1998, doi: 10.1109/6.715180.
- [56] T. C. Pearce, S. S. Schiffmann, H. T. Nagle, and J. W. Gardner, "Handbook of Machine Olfaction," Second Edition, WILEY-VCH, Germany, 2003.
- [57] D. James, S. Scott, Z. Ali, and W. O'Hare, "Chemical sensors for electronic nose systems," *Microchim. Acta.*, vol. 149, no.1, pp. 1-17, 2005, doi: 10.1007/s00604-004-0291-6.
- [58] P. Kadiroğlu, "Classification of virgin olive oils from different olive varieties and geographical regions by electronic nose and detection of adulteration," Yüksek Lisans Tezi, Mühendislik ve Fen Bilimleri Enstitüsü, İzmir Yüksek Teknoloji Enstitüsü, İzmir, 2008.
- [59] M. Badura, P. Batog, A. Drzeniecka-Osiadacz, and P. Modzel, "Optical particulate matter sensors in PM 2.5 measurements in atmospheric air," *E3S Web of Conferences*, vol. 44, 00006, 2018, doi: 10.1051/e3sconf/20184400006.
- [60] M. E. Şahin, "Elektronik burun ve temel bileşen analizi ile mikroorganizmaların saptanması," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Dumlupınar Üniversitesi, Kütahya, 2008.

- [61] M. Shayegan and S. Aghabozorgi, "A New Dataset Size Reduction Approach for PCA-Based Classification in OCR Application," *Math. Probl. Eng.*, vol. 2014, pp. 1-14, 2014, doi: 10.1155/2014/537428.
- [62] B. H. Aksebzeci, "Mikroorganizmaların elektronik burun teknolojisi kullanılarak tanımlanması ve sınıflandırılması," Doktora Tezi, Fen Bilimleri Enstitüsü, Erciyes Üniversitesi, Kayseri, 2011.
- [63] Y. Kablan, "Elektronik Burun ile Farklı Kalitedeki Doğu Karadeniz Çaylarının Sınıflandırılması," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Karadeniz Teknik Üniversitesi, Trabzon, 2018.
- [64] R. Semaan and V. Yadav, "SCOUT: Signal Correction and Uncertainty Quantification Toolbox in MATLAB," *SoftwareX*, vol. 11, 100474, 2020, doi: 10.1016/j.softx.2020.100474.
- [65] C. Pan, R. Zhang, H. Luo, and H. Shen., "Baseline correction of vibration acceleration signals with inconsistent initial velocity and displacement," *Adv. Mech. Eng.*, vol. 8, pp. 1-11, 2016, doi: 10.1177/1687814016675534.
- [66] C. Distanto, M. Leo, P. Siciliano, and K. Persaud, "On the study of feature extraction methods for an electronic nose," *Sensor. Actuator. B: Chem.*, vol. 87, pp. 274-288, 2002, doi: 10.1016/S0925-4005(02)00247-2.
- [67] S. Güney, A. Atasoy, and R. Burget, "Electronic nose odor classification with advanced decision tree structures," *Radioengineering*, vol. 22, pp. 874-882, 2013.
- [68] J. Yan, X. Guo, S. Duan, P. Jia, L. Wang, C. Peng, and S. Zhang, "Electronic Nose Feature Extraction Methods: A Review," *Sensors*, vol. 15, pp. 27804-27831, 2015, doi: 10.3390/s151127804.
- [69] J. H. Cho and P. U. Kurup, "Decision tree approach for classification and dimensionality reduction of electronic nose data," *Sensor. Actuator. B: Chem.*, vol. 160, pp. 542-548, 2011, doi: 10.1016/j.snb.2011.08.027.
- [70] G. S. Linoff and M. J. Berry, "Data Mining Techniques: for Marketing, Sales and Customer Relationship Management," Indianapolis, Wiley Publishing Inc., 2011.

- [71] Z. Chen, Y. Zheng, K. Chen, H. Li, and J. Jian, "Concentration Estimator of Mixed VOC Gases Using Sensor Array with Neural Networks and Decision Tree Learning," *IEEE Sens. J.*, vol. 17, pp. 1884-1892, 2017, doi: 10.1109/JSEN.2017.2653400.
- [72] A. Yavuz, "Comparison of predictive performances of logistic regression and decision tree algorithms: An application of life satisfaction," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Dokuz Eylül Üniversitesi, İzmir, 2021.
- [73] E. Yıldız and Y. Sevim, "Comparison of linear dimensionality reduction methods on classification Methods," *2016 National Conference on Electrical, Electronics and Biomedical Engineering (ELECO)*, pp. 161-164, 2016.
- [74] V. Skrobot, E. Castro, R. Pereira, V. Pasa, and I. Fortes, "Use of Principal Component Analysis (PCA) and Linear Discriminant Analysis (LDA) in Gas Chromatographic (GC) Data in the Investigation of Gasoline Adulteration," *Energy & Fuels - ENERG FUEL.*, vol. 21, 2007, doi: 10.1021/ef0701337.
- [75] A. Martinez and A. C. Kak, "PCA versus LDA," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 23, pp. 228-233, 2001, doi: 10.1109/34.908974.
- [76] K. Torkkola, "Linear discriminant analysis in document Classification," in *IEEE ICDM workshop on text mining*, pp. 800-806, 2001.
- [77] S. Scott, D. James, and Z. Ali, "Data analysis for electronic nose systems," *Microchim. Acta.*, vol. 156, pp. 183-207, 2006, doi: 10.1007/s00604-006-0623-9.
- [78] B. Ghogh and M. Crowley, "Linear and Quadratic Discriminant Analysis: Tutorial," 2019.
- [79] A. Tharwat, "Linear vs. quadratic discriminant analysis classifier: a tutorial," *Int. J. Appl. Pattern Recognit.*, vol. 3, pp. 145-180, 2016, doi: 10.1504/IJAPR.2016.079050.
- [80] M. Panda and M. R. Patra, "Network intrusion detection using naive bayes," *International Journal of Computer Science and Network Security*, vol. 7, no. 12, pp. 258-263, 2007.

- [81] S. Mukherjee and N. Sharma, "Intrusion Detection using Naive Bayes Classifier with Feature Reduction," *Proc. Technol.*, vol. 4, pp. 119-128, 2012, doi: 10.1016/j.protcy.2012.05.017.
- [82] S. Güney and A. Atasoy, "Discrimination of different fish species by e-nose," in *Proceedings of 38th International Conference on Telecommunications and Signal Processing (TSP)*, Berlin, Germany, pp. 1-5, 2014, doi: 10.1109/TSP.2015.7296458.
- [83] M. Pardo and G. Sberveglieri, "Classification of electronic nose data with support vector machines," *Sensor. Actuator. B: Chem.*, vol. 107, pp. 730-737, 2005 doi: 10.1016/j.snb.2004.12.005.
- [84] W. S. Noble, "What is a support vector machine?," *Nat. Biotechnol.*, vol. 24, pp. 1565-1567, 2006, doi: 10.1038/nbt1206-1565.
- [85] M. Pal, N. K. Singh, and N. K. Tiwari, "Support vector regression-based modeling of pier scour using field data," *Eng. Appl. Artif. Intell.*, vol. 24, pp. 911-916, 2011, doi: 10.1016/j.engappai.2010.11.002.
- [86] L. Zhang, F. Tian, H. Nie, L. Dang, G. Li, Q. Ye, and C. Kadri, "Classification of multiple indoor air contaminants by an electronic nose and a hybrid support vector machine," *Sensor. Actuator. B: Chem.*, vol. 174, pp. 114-125, 2012, doi: 10.1016/j.snb.2012.07.021.
- [87] A. R. Özcan, "Gömülü yaya belirleme sistemi tasarımı ve gerçeklemesi," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Yıldız Teknik Üniversitesi, İstanbul, 2013.
- [88] I. Saini, D. Singh, and A. Khosla, "QRS detection using K-nearest neighbor algorithm (KNN) and evaluation on standard ECG data bases," *J. Adv. Res.*, vol. 4, pp. 331-334, 2013, doi: 10.1016/j.jare.2012.05.007.
- [89] G. Haixiang, L. Yijing, L. Yanan, L. Xiao, and L. Jinling, "BPSO-Adaboost-KNN ensemble learning algorithm for multi-class imbalanced data Classification," *Eng. Appl. Artif. Intell.*, vol. 49, pp. 176-193, 2016, doi: 10.1016/j.engappai.2015.09.011.

- [90] M. B. Banerjee, R. B. Roy, B. Tudu, R. Bandyopadhyay, and N. Bhattacharyya, "Black tea classification employing feature fusion of E-Nose and E-Tongue responses," *J. Food Eng.*, vol. 244, pp. 55–63, 2019, doi: 10.1016/j.jfoodeng.2018.09.022.
- [91] K. E. Schackart and Y. Jeong-Yeol, "Machine Learning Enhances the Performance of Bioreceptor-Free Biosensors," *Sensors*, vol. 21, no. 16, 5519, 2021, doi: 10.3390/s21165519.
- [92] M. Skurichina and R. P. W. Duin, "Bagging, boosting and the random subspace method for linear classifiers," *Pattern Anal. Appl.*, vol. 5, pp. 121–135, 2002, doi: 10.1007/s100440200011.
- [93] P. Panov and S. Dzeroski, "Combining Bagging and Random Subspaces to Create Better Ensembles," LNCS 4723 (2007) 118-129, doi: 10.1007/978-3-540-74825-0_11.
- [94] G. Yangın, "XGBOOST ve karar ağacı tabanlı algoritmaların diyabet veri setleri üzerine uygulaması," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Mimar Sinan Güzel Sanatlar Üniversitesi, İstanbul, 2019.
- [95] H. Yu and J. Ni, "An Improved Ensemble Learning Method for Classifying High-Dimensional and Imbalanced Biomedicine Data," *IEEE/ACM Trans. Comput. Biol. Bioinform*, vol. 11, pp. 657-666, 2014, doi:10.1109/TCBB.2014.2306838.
- [96] F. Bilgin, "PAF screening from sinus rhythm ECG records by ensemble learning," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Dokuz Eylül Üniversitesi, İzmir, 2017.
- [97] A. T. Tekin, "Fuzzy clustering based ensemble learning approach: Applications in digital advertising," Doktora Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2021.
- [98] A. Onan and S. Korukoğlu, "Ensemble methods for opinion mining," in *Proceedings of the 23rd Signal Processing and Communications Applications Conference (SIU)*, IEEE, New York, 2015, pp. 212-215.
- [99] P. Yıldırım, K. U. Birant, V. Radevski, A. Kut, and D. Birant, "Comparative analysis of ensemble learning methods for signal Classification," *2018 26th Signal Processing*

and Communications Applications Conference (SIU), 2018, pp. 1-4, doi: 10.1109/SIU.2018.8404601.

- [100] N. Moarref, “Dissimilarity based multiple instance learning using dictionary ensembles,” Yüksek Lisans Tezi, Fen Mühendisliği ve Teknoloji Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2017.
- [101] A. J. Smola and B. Schölkopf, “A tutorial on support vector regression,” *Stat. Comput.*, vol. 14, pp. 199-222, 2004, doi: 10.1023/B%3ASTCO.0000035301.49549.88.
- [102] K. Uçak, “Destek vektör regresyonu ile PID kontrolör tasarımı,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2012.
- [103] M. Awad and R. Khanna, “Support Vector Regression,” in *Efficient Learning Machines*, Apress, Berkeley, CA, 2015, doi: 10.1007/978-1-4302-5990-9_4.
- [104] R. Laref, E. Losson, A. Sava, and M. Siadat, “Support vector machine regression for calibration transfer between electronic noses dedicated to air pollution monitoring,” *Sensors*, vol. 18, no. 11, pp. 1-11, 2018, doi: 10.3390/s18113716.
- [105] M. Daş, N. Balpetek, E. Kavak Akpınar, and S. Akpınar, “Investigation of wind energy potential of different provinces found in Turkey and establishment of predictive model using support vector machine regression with the obtained Results,” *J. Fac. Eng. Archit. Gazi Univ.*, vol. 3, no. 4, pp. 2203-2213, 2019, doi: 10.17341/gazimmfd.432590.
- [106] M. Peker, O. Özkaraca, and B. Kesimal, “Enerji tasarruflu bina tasarımı için ısıtma ve soğutma yüklerini regresyon tabanlı makine öğrenmesi algoritmaları ile modelleme,” *Bilişim Teknolojileri Dergisi*, pp. 443-449, 2017, doi: 10.17671/gazibtd.310154.
- [107] M. Xu, P. Watanachaturaporn, P. K. Varshney, and M. K. Arora, “Decision tree regression for soft classification of remote sensing data,” *Remote Sens. Environ.*, vol. 97, pp. 322-336, 2005, doi: 10.1016/j.rse.2005.05.008.
- [108] D. Özkaya, “Comparison of machine learning algorithms for blood glucose prediction on aida simulator,” Yüksek Lisans Tezi, Biyo-Medikal Mühendislik Enstitüsü, Boğaziçi Üniversitesi, İstanbul, 2011.

- [109] J. -S. Chou, N. -T. Ngo, and W. K. Chong, “The use of artificial intelligence combiners for modeling steel pitting risk and corrosion rate,” *Eng. Appl. Artif. Intell.*, vol. 65, pp. 471–483, 2017, doi: 10.1016/j.engappai.2016.09.008.
- [110] M. E. Irmak and İ. B. Aydılek, “Hava Kalite İndeksinin Tahmin Başarısının Artırılması için Topluluk Regresyon Algoritmalarının Kullanılması,” *Academic Platf. J. Eng. Sci.*, 7–3, pp. 507–514, 2019.
- [111] E. Pekel, “Estimation of soil moisture using decision tree regression,” *Theor. Appl. Climatol.*, vol. 139, pp. 1111–1119, 2020, doi: 10.1007/s00704-019-03048-8.
- [112] E. Ardiç, “Işık spektrum verisinden madde özelliklerinin tahmini için makine öğrenmesi teknikleri,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Gebze Teknik Üniversitesi, Gebze, 2018.
- [113] Ş. Seyhan, “Dayanma duvarlarında makine öğrenmesi ile güvenlik sayısı tahmini,” Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, KTO Karatay Üniversitesi, Konya, 2021.
- [114] F. Sulan, “Şebeke bağlantılı güneş enerji santralinin güç verimliliğinin performans analizi ve tahmini,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Erzurum Teknik Üniversitesi, Erzurum, 2022.
- [115] S. Hong, Z. Zhou, C. Lu, K. Heart, and T. Zhao, “Bearing remaining life prediction using Gaussian process regression with composite kernel functions,” *J. Vibroengineering*, vol. 17, pp. 695-704, 2015.
- [116] R. R. Richardson, M. A. Osborne, and D. A. Howey, “Gaussian process regression for forecasting battery state of health,” *J. Power Sources*, vol. 357, pp. 209-219, 2017, doi: 10.1016/j.jpowsour.2017.05.004.
- [117] H. Azizoltani and E. Sadeghi, “Adaptive sequential strategy for risk estimation of engineering systems using Gaussian process regression active learning,” *Eng. Appl. Artif. Intell.*, vol. 74, pp. 146–165, 2018, doi: 10.1016/j.engappai.2018.06.007.

- [118] J. Fairbrother, C. Nemeth, M. Rischard, and J. Brea, “GaussianProcesses.jl: A Nonparametric Bayes package for the Julia Language,” arXiv:1812.09064v2, 2018, doi: 10.48550/arXiv.1812.09064.
- [119] J. -A. Goulet, “Probabilistic Machine Learning for Civil Engineers,” *The MIT Press*, 2020.
- [120] D. Yergök, “Yapay zekâ yöntemleri ile toplu yemek üretiminde günlük talep tahmini,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Mersin Üniversitesi, Mersin, 2020.
- [121] E. Altınok, “Data-driven modeling of ultimate load capacity of closed- and open-ended piles using machine learning,” Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2021.
- [122] X. Su, X. Yan, and C. Tsai, “Linear regression,” *Wiley Interdiscip. Rev. Comput. Stat.*, vol. 4, pp. 275-294, 2012, doi: 10.1002/wics.1198.
- [123] G. S. Shokouh, “Gerçek zamanlı sayısal görüntü işleme ve örüntü tanıma tekniklerinin araştırılması ve uygulanması,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Ankara Üniversitesi, Ankara, 2013.
- [124] V. Mathew, T. Toby, V. Singh, B. M. Rao, and M. G. Kumar, “Prediction of Remaining Useful Lifetime (RUL) of turbofan engine using machine learning,” *2017 IEEE International Conference on Circuits and Systems (ICCS)*, pp. 306-311, 2017, doi: 10.1109/ICCS1.2017.8326010.
- [125] R. A. Oliveira and M. H. J. Bollen, “Deep learning for power quality,” *Electr. Power Syst. Res.*, vol. 214, 2023, 108887, 2023, doi: 10.1016/j.epsr.2022.108887.
- [126] F. Uzman, “Estimating Physical Properties of the Products of an Atmospheric Distillation Column by Support Vector Regression,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Koç Üniversitesi, 2015.
- [127] E. Özaydın, “Building detection from very high resolution satellite images with deep learning approach,” Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2021.

- [128] H. E. Çalık, “An ensemble classification model for detecting voice phishing in telecommunication networks and its integration into a visual analysis tool,” Yüksek Lisans Tezi, Mühendislik ve Fen Bilimleri Enstitüsü, Bilkent Üniversitesi, 2022.
- [129] M. Keleş, “Filling the data gap between grace and grace follow-on missions using deep learning algorithms,” Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Teknik Üniversitesi, 2022.
- [130] Y. T. Tsai, Y. R. Zeng, and Y. S. Chang, “Ari pollution forecasting using RNN with LSTM,” in *Proceedings of the 2018 IEEE 16th Int. Conf. on Dependable, Autonomic & Secure Comp., 16th Int. Conf. on Pervasive Intelligence & Comp., 4th Int. Conf. on Big Data Intelligence & Comp., and 3rd Cyber Sci. & Tech. Cong.*, pp. 1074-1079, 2018, doi: 10.1109/DASC/PiCom/DataCom/CyberSciTec.2018.00178.
- [131] D. Wang, J. Fan, H. Fu, and B. Zhang, “Research on optimization of big data construction engineering quality management based on RNN-LSTM,” *Complexity*, vol. 2018, article id. 9691868, 2018, doi: 10.1155/2018/9691868.
- [132] N. Michelle, U. Rajendra Acharya, and F. Molinari, “Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG signals,” *Comput. Biol. Med.*, vol. 106, pp. 71–81, 2019, doi: 10.1016/j.combiomed.2019.01.013.
- [133] L. Wang, W. Huang, Z. Yang, and C. Zhang, “Temporal-spatial-frequency depth extraction of brain-computer interface based on mental tasks,” *Biomed. Signal Process. Control*, vol. 58, 101845, 2020, doi: 10.1016/j.bspc.2020.101845.
- [134] Ç. E. Yıldız, “A comparison of LSTM and GNN based session recommendation systems,” Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2021.
- [135] H. Anıl, “Effects of geothermal production prediction on the energy market with artificial intelligence Methods,” Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, Bahçeşehir Üniversitesi, 2022.
- [136] B. Asefisaray, “Uçtan-uca konuşma tanıma modeli: Türkçe’deki deneyler,” Doktora Tezi, Fen Bilimleri Enstitüsü, Hacettepe Üniversitesi, Ankara, 2018.

- [137] L. Ni, D. Wang, V. P. Singh, J. Wu, Y. Wang, Y. Tao, and J. Zhang, "Streamflow and rainfall forecasting by two long short-term memory-based models," *J. Hydrol*, vol. 583, 124296, 2020, doi: 10.1016/j.jhydrol.2019.124296.
- [138] V. Bui, N. T. Le, V. H. Nguyen, J. Kim, and Y. M. Jang, "Multi-Behavior with Bottleneck Features LSTM for Load Forecasting in Building Energy Management System," *Electronics*, vol. 10, no. 9, 1026, 2021, doi: 10.3390/electronics10091026.
- [139] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to forget: Continual prediction with LSTM," *Neural Comput.*, vol. 12, pp. 2451–2471, 2000, doi: 10.1162/089976600300015015.
- [140] M. A. A. Elhag, Modeling diesel oxidation catalyst exhaust gas temperatures using long short-term memory recurrent neural networks," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Yıldız Teknik Üniversitesi, İstanbul, 2018.
- [141] M. Phi. "Illustrated guide to LSTM's and GRU's: A step by step explanation." towardsdatascience.com. bitly.ws/A4mk (Erişim: Tem. 20, 2022).
- [142] M. Fernández-Díaz and A. Gallardo-Antolín, "An attention Long Short-Term Memory based system for automatic classification of speech intelligibility," *Eng. Appl. Artif. Intell.*, vol. 96, 103976, 2020, doi: 10.1016/j.engappai.2020.103976.
- [143] Z. Karevan and J. A. K. Suykens, "Transductive LSTM for time-series prediction: An application to weather forecasting," *Neural Netw.*, vol. 125, pp. 1–9, 2020, doi: 10.1016/j.neunet.2019.12.030.
- [144] A. H. Elsheikh, V. P. Katekar, O. L. Muskens, S. S. Deshmukh, M. A. Elaziz, and S. M. Dabour, "Utilization of LSTM neural network for water production forecasting of a stepped solar still with a corrugated absorber plate," *PSEP*, vol. 148, pp. 273-282, 2021, doi: 10.1016/j.psep.2020.09.068.
- [145] N. Vahabi and D. R. Selviah, "Convolutional Neural Networks to Classify Oil, Water and Gas Wells Fluid Using Acoustic Signals," *2019 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*, pp. 1-6, 2019, doi: 10.1109/ISSPIT47144.2019.9001845.

- [146] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation," in *Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 580-587, 2014, doi: 10.1109/CVPR.2014.81.
- [147] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998, doi: 10.1109/5.726791.
- [148] U. Mutlu, "Aircraft detection using deep learning," Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2022.
- [149] E. A. Smirnov, D. M. Timoshenko, and S. N. Andrianov, "Comparison of Regularization Methods for ImageNet Classification with Deep Convolutional Neural Networks," *AASRI Procedia*, vol. 6, pp. 89-94, 2014, doi: 10.1016/j.aasri.2014.05.013.
- [150] M. Lopez and W. Yu, "Nonlinear system modeling using convolutional neural networks," *2017 14th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)*, 2017, pp. 1-5, doi: 10.1109/ICEEE.2017.8108894.
- [151] H. Cho and S. M. Yoon, "Divide and Conquer-Based 1D CNN Human Activity Recognition Using Test Data Sharpening," *Sensors (Basel, Switzerland)*, vol. 18, 2018, doi:10.3390/s18041055.
- [152] S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci, and M. Gabbouj, "1-D Convolutional Neural Networks for Signal Processing Applications," *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 8360-8364, 2019, doi: 10.1109/ICASSP.2019.8682194.
- [153] X. Zhao, Z. Wen, X. Pan, W. Ye, and A. Bermak, "Mixture Gases Classification Based on Multi-Label One-Dimensional Deep Convolutional Neural Network," in *IEEE Access*, vol. 7, pp. 12630-12637, 2019, doi: 10.1109/ACCESS.2019.2892754.
- [154] G. B. Cangöz, "Köpeklerin uzun kemiklerinin ve uzun kemiklerindeki kırıkların sınıflandırılması," Doktora Tezi, Fen Bilimleri Enstitüsü, Başkent Üniversitesi, Ankara, 2022.

- [155] F. Kurt, “Evrışimli sinir ağlarında hiper parametrelerin etkisinin incelenmesi,” Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Hacettepe Üniversitesi, Ankara, 2018.
- [156] N. Jmour, S. Zayen, and A. Abdelkrim, “Convolutional neural networks for image Classification,” in *Proceedings of 2018 International Conference on Advanced Systems and Electric Technologies (IC_ASET)*, pp. 397-402, 2018, doi: 10.1109/ASET.2018.8379889.
- [157] A. Gülcü and Z. Kuş, “A Survey of Hyper-parameter Optimization Methods in Convolutional Neural Networks,” *Gazi Üniversitesi Fen Bilimleri Dergisi*, vol. 7, no. 2, pp. 503-522, 2019, doi: 10.29109/gujsc.514483.
- [158] M. Ege, “Human activity classification with deep learning using FMCW radar,” Yüksek Lisans Tezi, Mühendislik ve Fen Bilimleri Enstitüsü, Bilkent Üniversitesi, 2022.
- [159] A. Biswal. “Convolutional Neural Network Tutorial.” simplilearn.com. bitly.ws/piyX (Erişim: Ara. 18, 2022).
- [160] D. L. H Sheng. “An Overview of Convolutional Neural Network (CNN).” medium.com. bitly.ws/A4mW (Erişim: Nis. 16, 2022).
- [161] B. N. Wiysobunri, “CNN-based server state monitoring and fault diagnosis using infrared thermography,” Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Teknik Üniversitesi, 2022.
- [162] C. Lea, R. Vidal, A. Reiter, and G. D. Hager, “Temporal Convolutional Networks: A Unified Approach to Action Segmentation,” *Lecture Notes in Computer Science*, pp. 1-4, 2016, doi: 10.1007/978-3-319-49409-8_7.
- [163] S. Bai, J. Z. Kolter, and V. Koltun, “An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling,” *Preprint*, 2018, doi: 10.48550/arXiv.1803.01271.
- [164] A. V. D. Oord, S. Dieleman, H. Zen, K. Simonyan, O. Vinyals, A. Graves, N. Kalchbrenner, A. Senior, and K. Kavukcuoglu, “WaveNet: A generative model for raw audio,” 2016, doi: 10.48550/arXiv.1609.03499.

- [165] P. Zhao, Z. Fan, Z. Cao, and X. Li, "Intrusion detection model using temporal convolutional network blend into attention mechanism," *International Journal of Information Security and Privacy (IJISP)*, vol. 16, pp. 1-20, 2022, doi: 10.4018/IJISP.290832.
- [166] P. Lara-Benítez, M. Carranza-García, J. M. Luna-Romera, and J. C. Riquelme, "Temporal Convolutional Networks Applied to Energy-Related Time Series Forecasting," *Appl. Sci.*, vol. 10, 2322, 2020, doi: 10.3390/app10072322.
- [167] J. Fonollosa, L. Fernández, A. Gutiérrez-Gálvez, R. Huerta, and S. Marco, "Calibration transfer and drift counteraction in chemical sensor arrays using direct Standardization," *Sensor. Actuator. B: Chem.*, vol. 236, pp. 1044-1053, 2016, doi: 10.1016/j.snb.2016.05.089.
- [168] T. Keskin, "Energy demand forecasting in fog computing based microgrids using ensemble learning," Yüksek Lisans Tezi, Lisansüstü Eğitim Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul, 2021.
- [169] B. -Y. Sun, D. -S. Huang, and H. -T. Fang, "Lidar signal denoising using least-squares support vector machine," *IEEE Signal Process. Lett.*, vol. 12, no. 2, pp. 101–104, 2005, doi: 10.1109/LSP.2004.836938.
- [170] P. Chen, B. Wang, H. -S. Wong, and D. -S. Huang, "Prediction of protein B-factors using multi-class bounded SVM," *Protein Pept Lett.*, vol. 14, no. 2, pp. 185–190, 2007, doi: 10.2174/092986607779816078.
- [171] X. Liang, L. Zhu, and D. -S. Huang, "Multi-task ranking SVM for image cosegmentation," *Neurocomputing*, vol. 247, pp. 126–136, 2017, doi:10.1016/j.neucom.2017.03.060.
- [172] J. Cervantes, F. García Lamont, A. López-Chau, L. Rodríguez Mazahua, and J. Sergio Ruíz, "Data selection based on decision tree for SVM classification on large data sets," *Appl. Soft Comput. J.*, vol. 37, pp. 787-798, 2015, doi: 10.1016/j.asoc.2015.08.048.
- [173] V. A. Naik and A. A. Desai, "Online handwritten gujarati character recognition using SVM, MLP, and k-NN," in *2017 8th International Conference on Computing*,

Communication and Networking Technologies (ICCCNT), pp. 1–6, 2017, doi: 10.1109/ICCCNT.2017.8203926.

- [174] T. K. Bhowmik, P. Ghanty, A. Roy, and S. K. Parui, “SVM-based hierarchical architectures for handwritten bangla character recognition,” *Int. J. Document Anal. Recogn. (IJDAR)*, vol. 12, pp. 97–108, 2009, doi: 10.1007/s10032-009-0084-x.
- [175] J. C. Rodriguez Gamboa, A. J. da Silva, I. C. S. Araujo, E. S. Albarracin E., and C. M. Duran A., “Validation of the rapid detection approach for enhancing the electronic nose systems performance, using different deep learning models and support vector machines,” *Sensor. Actuator. B: Chem.*, vol. 327, pp. 1-7, 2021, doi: 10.1016/j.snb.2020.128921.
- [176] C. Zhang, W. Wang, Y. Pan, and S. Zhai, “Rapid gas detection for electronic noses using optimal measurement time search and multi-sensor energy change based feature extraction,” *Measurement*, vol. 204, pp. 1-11, 2022, doi: 10.1016/j.measurement.2022.112101.
- [177] C. Zhang, W. Wang, Y. Pan, and S. Zhai, “Curriculum Learning-Based Approaches for End-to-End Gas Recognition,” in *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1-11, 2022, Art no. 2518611, doi: 10.1109/TIM.2022.3205901.
- [178] R. Yi, J. Yan, D. Shi, Y. Tian, F. Chen, Z. Wang, and S. Duan, “Improving the performance of drifted/shifted electronic nose systems by cross-domain transfer using common transfer samples,” *Sensor. Actuator. B: Chem.*, vol. 329, pp. 1-13, 2021, doi: 10.1016/j.snb.2020.129162.