T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

HAVA KALİTESİNİN İNCELENMESİ ve EĞİTİLEBİLİR ALGORİTMALARDA MODELLENMESİNİN ARAŞTIRILMASI; ÇERKEZKÖY ÖRNEĞİ

Hüseyin ÖZEL

DANIŞMAN
Prof. Dr. Hüseyin Kurtuluş ÖZCAN

II. DANIŞMAN
Dr. Öğr. Üyesi Pınar CİHAN

Çevre Mühendisliği Anabilim Dalı

Çevre Mühendisliği Programı

Haziran, 2022

TEZ KABUL VE ONAYI

Hüseyin ÖZEL tarafından, **Prof. Dr. Hüseyin Kurtuluş ÖZCAN** danışmanlığında hazırlanan **"HAVA KALİTESİNİN İNCELENMESİ VE EĞİTİLEBİLİR ALGORİTMALARDA MODELLENMESİNİN ARAŞTIRILMASI; ÇERKEZKÖY ÖRNEĞİ"** başlıklı bu çalışma, jürimiz tarafından **29/06/2022** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Doktora Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Prof. Dr. Hüseyin Kurtuluş ÖZCAN İstanbul Üniversitesi Cerrahpaşa Çevre Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. Serdar AYDIN İstanbul Üniversitesi Cerrahpaşa Çevre Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. Asude HANEDAR Tekirdağ Namık Kemal Üniversitesi Çevre Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Doç. Dr. Atakan ÖNGEN İstanbul Üniversitesi Cerrahpaşa Çevre Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. Elçin GÜNEŞ Tekirdağ Namık Kemal Üniversitesi Çevre Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret

Oğullarıma ithaf ediyorum…

BÜTÇE DESTEKLERİ

HAVA KALİTESİNİN İNCELENMESİ VE EĞİTİLEBİLİR ALGORİTMALARDA MODELLENMESİNİN ARAŞTIRILMASI; ÇERKEZKÖY ÖRNEĞİ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Doktora öğrenimim ve tezimin hazırlanması sürecinde yol göstericiliği, anlayışı ve bilimsel katkısına ilave olarak her türlü yardımı ve desteği gösteren tez danışmanı değerli hocam Sayın Prof. Dr. Hüseyin Kurtuluş ÖZCAN'a, tezimin hazırlanmasında ikinci danışmanlığıyla katkı sağlayan, bilgisi ve deneyimi ile desteğini hiçbir zaman esirgemeyen Sayın Dr. Öğr. Üyesi Pınar CİHAN'a, gösterdiği fedakârlık, destek ve sevgisiyle yanımda olan eşime tüm içtenliğimle teşekkür ediyorum.

Haziran 2022 **Hüseyin ÖZEL**

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **Hata! Yer işareti tanımlanmamış.**
BÜTÇE DESTEKLERİ ..... **iv**
TEŞEKKÜR ..... **v**
İÇİNDEKİLER ..... **vi**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **xii**
SİMGE VE KISALTMA LİSTESİ ..... **xiv**
ÖZET ..... **xvi**
ABSTRACT ..... **xviii**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **3**
2.1. HAVA KİRLİLİĞİ 3
2.2. HAVA KİRLİLİĞİ KAYNAKLARI 4
2.3. HAVA KİRLETİCİLER 5
2.3.1. Partikül Madde (PM) 5
2.3.2. Azot Oksitler (NO_x) 7
2.3.3. Kükürt Dioksit (SO_2) 8
2.3.4. Karbon Monoksit (CO) 10
2.3.5. Hidrokarbonlar (HC) 11
2.4. HAVA KALİTESİ STANDARTLARI 12
2.5. HAVA KALİTESİ İNDEKSİ 13
2.6. HAVA DURUMU, İKLİM ve METEOROLOJİK PARAMETRELER 14
2.6.1. Sıcaklık 15
2.6.2. Basınç 16
2.6.3. Yağış 17
2.6.4. Rüzgâr 17
2.7. EĞİTİLEBİLİR ALGORİTMALAR 18

2.7.1. Makine Öğrenmesi 19
2.7.2. Bulanık Mantık 20
2.7.3. Yapay Sinir Ağları 21
2.7.4. Genetik Algoritma 22
2.7.5. Uzman Sistemler 23
2.8. EĞİTİLEBİLİR ALGORİTMA MODELLERİ 24
2.8.1. Adaptif Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neuro Fuzzy Inference System, ANFIS) 24
2.8.2. Destek Vektör Regresyonu (Support Vector Regression, SVR) 25
2.8.3. Kümeleme ve Regresyon Ağaçları (Classification and Regression Trees, CART) 26
2.8.4. Rastgele Orman (Random Forest, RF) 27
2.8.5. K-En Yakın Komşu Algoritması (K-Nearest Neighbor, KNN) 28
2.8.6. Aşırı Öğrenme Makinesi (Extreme Learning Machine, ELM) 29
2.9. R PROGRAMLAMA 29
2.10. LİTERATÜR ARAŞTIRMASI 30
3. YÖNTEM 33
3.1. ÇALIŞMA BÖLGESİ 33
3.2. VERİ SETİ 34
3.3. ÇALIŞMA BÖLGESİ İLE KARŞILAŞTIRILAN BÖLGELER 36
3.4. MODEL DEĞERLENDİRME METRİKLERİ 38
3.4.1. Korelasyon Katsayısı (R) 38
3.4.2. Ortalama Mutlak Hata (MAE) 38
3.4.3. Ortalama Karesel Hatanın Karekökü (RMSE) 39
3.5. VERİLERİN NORMALİZASYONU 39
3.6. HAVA KİRLİLECİLER MODELLEME ÇALIŞMASI 40
3.7. HAVA KALİTESİ İNDEKSİ VE COVID-19 PANDEMİSİ SÜRECİ 41
4. BULGULAR 42
4.1. HAVA KALİTESİNİN İNCELENMESİ 42
4.1.1. Verilerin Yıllık Dağılımı 42
4.1.2. Verilerin Mevsimlik Dağılımı 49
4.1.3. Çerkezköy Hava Kalitesi Ölçüm İstasyonu Kirletici Konsantrasyonlarının Sınır Değerler ile İncelenmesi 54
4.1.4. Ölçüm İstasyonları Karşılaştırması 56
4.1.5. Hava Kalitesi İndeksi Değişimi 64
4.2. HAVA KALİTESİNİN EĞİTİLEBİLİR ALGORİTMALARDA MODELLENMESİ 66

4.2.1. Kirletici Parametreler ile Meteorolojik Parametreler Arasındaki İlişki 66
4.2.2. Veri Frekansı ve Dağılımı 68
4.2.3. Modellerin Tahmin Performanslarının Karşılaştırması 73
5. TARTIŞMA 80
6. SONUÇ VE ÖNERİLER 84
KAYNAKLAR 88
İNTİHAL RAPORU İLK SAYFASI 97
ETİK KURUL İZİN YAZISI ..... Hata! Yer işareti tanımlanmamış.
KURUM İZNİ YAZILARI ..... Hata! Yer işareti tanımlanmamış.
ÖZGEÇMİŞ ..... Hata! Yer işareti tanımlanmamış.

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Partikül maddenin kökeni ve özellikleri (Heil, 1998).....6

Şekil 2.2: Rüzgâr yönleri.....18

Şekil 2.3: Yapay zekâ ve veri bilimi diyagramı.....19

Şekil 2.4: Yapay sinir ağı diyagramı.....22

Şekil 2.5: ANFIS mimarisi.....24

Şekil 2.6: Destek vektör regresyonu diyagramı (Drucker ve diğ., 1996).....26

Şekil 2.7: Kümeleme ve regresyon ağaçları genel yapısı.....27

Şekil 2.8: Rastgele orman yöntemi genel yapısı.....28

Şekil 2.9: K-en yakın komşu yöntemi genel yapısı.....29

Şekil 3.1: Çalışma alanı.....33

Şekil 3.2: Çerkezköy istasyonunun konumunu gösteren uydu görüntüsü.....35

Şekil 3.3: Kocaeli Dilovası istasyonu konumunu gösteren uydu görüntüsü.....36

Şekil 3.4: Konya Selçuklu istasyonu konumunu gösteren uydu görüntüsü.....37

Şekil 3.5: Kayseri OSB istasyonu konumunu gösteren uydu görüntüsü.....37

Şekil 3.6: Yalova Armutlu istasyonu konumunu gösteren uydu görüntüsü.....37

Şekil 3.7: Akış diyagramı.....40

Şekil 4.1: PM_{10}, $PM_{2.5}$ ve SO_2 aylık değişim grafiği.....43

Şekil 4.2: PM_{10}, $PM_{2.5}$ ve CO aylık değişim grafiği.....44

Şekil 4.3: PM_{10}, $PM_{2.5}$ ve NO_2 aylık değişim grafiği.....44

Şekil 4.4: PM_{10}, $PM_{2.5}$ ve NO_x aylık değişim grafiği.....44

Şekil 4.5: PM_{10}, $PM_{2.5}$ ve NO aylık değişim grafiği.....45

Şekil 4.6: PM_{10}, $PM_{2.5}$ ve ortalama sıcaklık aylık değişim grafiği.....45

Şekil 4.7: PM_{10}, $PM_{2.5}$ ve ortalama rüzgâr yönü aylık değişim grafiği.....45

Şekil 4.8: PM_{10}, $PM_{2.5}$ ve rüzgâr hızı aylık değişim grafiği.....46

Şekil 4.9: PM_{10}, $PM_{2.5}$ ve toplam yağış aylık değişim grafiği. 46

Şekil 4.10: 2019-2020 yılları arası hava kalitesi değişimi. 47

Şekil 4.11: ÇOSB elektrik tüketim değerleri. 48

Şekil 4.12: ÇOSB doğalgaz tüketim değerleri. 48

Şekil 4.13: PM_{10}, $PM_{2.5}$ ve SO_2 mevsimsel değişim grafiği. 50

Şekil 4.14: PM_{10}, $PM_{2.5}$ ve CO mevsimsel değişim grafiği. 51

Şekil 4.15: PM_{10}, $PM_{2.5}$ ve NO_2 mevsimsel değişim grafiği.....51

Şekil 4.16: PM_{10}, $PM_{2.5}$ ve NO_x mevsimsel değişim grafiği. 51

Şekil 4.17: PM_{10}, $PM_{2.5}$ ve NO mevsimsel değişim grafiği. 52

Şekil 4.18: PM_{10}, $PM_{2.5}$ ve ortalama sıcaklık mevsimsel değişim grafiği. 52

Şekil 4.19: PM_{10}, $PM_{2.5}$ ve ortalama rüzgâr yönü mevsimsel değişim grafiği. 53

Şekil 4.20: PM_{10}, $PM_{2.5}$ ve rüzgâr hızı mevsimsel değişim grafiği. 53

Şekil 4.21: PM_{10}, $PM_{2.5}$ ve toplam yağış mevsimsel değişim grafiği. 53

Şekil 4.22: PM_{10} konsantrasyonu yıllık değişimi.....58

Şekil 4.23: SO_2 konsantrasyonu yıllık değişimi.....61

Şekil 4.24: Yılık NO_2 ve PM_{10} konsantrasyonu yıllık değişimi.....64

Şekil 4.25: Yıllık hava kalitesi indeks oranları dağılımı.....66

Şekil 4.26: PM_{10} ile kirletici ve meteorolojik parametreler arasındaki ilişki matrisi.....67

Şekil 4.27: $PM_{2.5}$ ile kirletici ve meteorolojik parametreler arasındaki ilişki matrisi. 68

Şekil 4.28: Kirletici konsantrasyonu ve meteorolojik veri frekansları. 69

Şekil 4.29: Rüzgâr yönü frekansı (%). 70

Şekil 4.30: SO_2, CO, NO, NO_2 ve NO_x yıllık dağılım grafikleri. 71

Şekil 4.31: $PM_{2.5}$ ve PM_{10} yıllık dağılım grafikleri.....71

Şekil 4.32: Sıcaklık, rüzgâr yönü (RY), rüzgâr hızı (RH), yağış yıllık dağılım grafikleri. 72

Şekil 4.33: Kirletici ve meteorolojik veriler ile PM_{10} tahmini model çıktıları. 74

Şekil 4.34: Kirletici veriler ile PM_{10} tahmini model çıktıları. 74

Şekil 4.35: Meteorolojik veriler ile PM_{10} tahmini model çıktıları. 74

Şekil 4.36: Kirletici ve meteorolojik veriler ile $PM_{2.5}$ tahmini model çıktıları. 75

Şekil 4.37: Kirletici veriler ile $PM_{2.5}$ tahmini model çıktıları. 75

Şekil 4.38: Meteorolojik veriler ile $PM_{2.5}$ tahmini model çıktıları. 75

Şekil 4.39: PM_{10} model tahmin başarı karşılaştırması. 79

Şekil 4.40: $PM_{2.5}$ model tahmin başarı karşılaştırması. 79

TABLO LİSTESİ

Sayfa No

Tablo 2.1: Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği'ne göre kirleticilerin sınır değerleri. 12

Tablo 2.2: PM_{10} ve $PM_{2.5}$ sınır değerleri (DSÖ, 2006)..... 13

Tablo 2.3: Hava kalitesi indeksi kesme noktaları (EPA, 2018)..... 14

Tablo 2.4: Ulusal hava kalitesi indeksi kesme noktaları (UHKİA, 2020)..... 14

Tablo 3.1: Veri seti istatistiği..... 35

Tablo 4.1: Tekirdağ iline ait genel istatistiki veriler (1939-2020 yılları arası). 43

Tablo 4.2: Tekirdağ iline ait mevsim normalleri. 49

Tablo 4.3: Çerkezköy istasyonu ölçülen PM_{10} konsantrasyonunun sınır değerler ile kıyaslanması. 54

Tablo 4.4: Çerkezköy istasyonu ölçülen $PM_{2.5}$ konsantrasyonunun sınır değerler ile kıyaslanması. 55

Tablo 4.5: Çerkezköy istasyonu ölçülen SO_2 konsantrasyonunun sınır değerler ile kıyaslanması. 55

Tablo 4.6: Çerkezköy istasyonu ölçülen NO_x konsantrasyonunun sınır değerler ile kıyaslanması. 56

Tablo 4.7: Çerkezköy istasyonu ölçülen NO_2 konsantrasyonunun sınır değerler ile kıyaslanması. 56

Tablo 4.8: Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB ve Yalova Armutlu istasyonlarında ölçülen PM_{10} konsantrasyonlarının sınır değerler ile kıyaslanması. 57

Tablo 4.9: Kayseri OSB ve Yalova Armutlu istasyonlarında ölçülen $PM_{2.5}$ konsantrasyonunun sınır değerler ile kıyaslanması. 59

Tablo 4.10: Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB, Yalova Armutlu istasyonlarında ölçülen SO_2 konsantrasyonlarının sınır değerler ile kıyaslanması. 60

Tablo 4.11: Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB ve Yalova Armutlu istasyonlarında ölçülen NO_x konsantrasyonlarının sınır değerler ile kıyaslanması. 62

Tablo 4.12: Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB ve Yalova Armutlu istasyonlarında ölçülen NO_2 konsantrasyonlarının sınır değerler ile kıyaslanması. 63

Tablo 4.13: 2016 yılı günlük hava kalitesi indeksi değişimi. 64

Tablo 4.14: 2017 yılı günlük hava kalitesi indeksi değişimi. 65

Tablo 4.15: 2018 yılı günlük hava kalitesi indeksi değişimi. 65

Tablo 4.16: 2019 yılı günlük hava kalitesi indeksi değişimi. 65

Tablo 4.17: Kirletici ve meteorolojik verilerden modellerin PM tahmin performansları. 76

Tablo 4.18: Kirletici verilerden modellerin PM tahmin performansları..... 77

Tablo 4.19: Meteorolojik verilerden modellerin PM tahmin performansları. 77

Tablo 5.1: Literatür kıyaslaması. 82

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
m	: Metre
n	: Veri seti boyutu
o	: Gerçek değer ortalaması
o_i	: Gerçek değer
p_i	: Tahmin değeri
R	: Korelasyon katsayısı
R^2	: Belirleme katsayısı
s	: Saniye
X'	: Normalize edilmiş değer
X	: Normalize edilecek değer
X_{min}	: Değerler kümesinin minimumu
X_{max}	: Değerler kümesinin maksimumu
^{o}	: Derece

Kısaltmalar	Açıklama
AB	: Avrupa Birliği
ANFIS	: Adaptif sinirsel bulanık çıkarım sistemi
BM	: Birleşmiş Milletler
CART	: Kümeleme ve regresyon ağaçları
CO	: Karbon monoksit
ÇOSB	: Çerkezköy Organize Sanayi Bölgesi
ÇŞB	: T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı
DSÖ	: Dünya Sağlık Örgütü
ELM	: Aşırı öğrenme makinesi
GA	: Genetik algoritma
HC	: Hidrokarbonlar
HKİ	: Hava kalitesi indeksi
KNN	: K-en yakın komşu algoritması

MAE : Ortalama mutlak hata
NO : Azot monoksit
NO_2 : Azot dioksit
NO_x : Azot oksitler
RH : Rüzgar hızı
PM : Partikül madde
$PM_{2.5}$: <2,5 μm çapındaki partikül madde
PM_{10} : <10 μm çapındaki partikül madde
RF : Rastgele orman
RMSE : Ortalama karesel hatanın karekökü
RY : Rüzgar yönü
SIC : Sıcaklık
SO_2 : Kükürt dioksit
SVR : Destek vektör regresyonu
US EPA : Birleşik Devletler Çevre Koruma Ajansı
YSA : Yapay sinir ağları
YAĞ : Yağış

ÖZET

DOKTORA TEZİ

HAVA KALİTESİNİN İNCELENMESİ VE EĞİTİLEBİLİR ALGORİTMALARDA MODELLENMESİNİN ARAŞTIRILMASI; ÇERKEZKÖY ÖRNEĞİ

Hüseyin ÖZEL

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Çevre Mühendisliği Anabilim Dalı

Çevre Mühendisliği Programı

Danışman: Prof. Dr. Hüseyin Kurtuluş ÖZCAN

II. Danışman: Dr. Öğr. Üyesi Pınar CİHAN

Hava kirliliğine neden olan kirleticiler gün geçtikçe artan miktarlarda atmosfere salınmaya devam etmektedir. Yoğun nüfusa sahip bölgelerde hava kirliliğine bağlı kısa ve uzun vadede çeşitli sağlık sorunları ortaya çıkmaktadır. Şehir ölçeğinde hava kalitesinin yüksek tutulabilmesi için hava kirliliğinin ölçümlerle takip edilmesi ve sonuçlara istinaden gereken önleyici politikaların uygulanması gerekmektedir. Hava kalitesinin belirlenmesinde matematiksel modeller kullanılarak hava kirleticilerinin ölçümü yapılabildiği gibi teknolojinin gelişimi ile yapay zekâ modelleri ile de kirleticilerin ölçüm sonuçları tahmin edilmektedir.

Bu çalışmada kentleşmenin ve sanayinin iç içe olduğu Çerkezköy lokasyonunda PM_{10} ve $PM_{2.5}$ kirleticilerinin zamansal değişimi analiz edilerek, ANFIS (Adaptif Sinirsel Bulanık Çıkarım Sistemi), SVR (Destek Vektör Regresyonu), CART (Kümeleme ve Regresyon Ağaçları), RF (Rastgele Orman), KNN (K-En Yakın Komşu Algoritması) ve ELM (Aşırı Öğrenme Makinesi) makine öğrenmesi metotları ile konsantrasyonlarının tahmin edilmesi amaçlanmıştır.

Bu amaçla; çalışmanın birinci bölümünde hava kirleticiler (PM_{10}, $PM_{2.5}$, SO_2, NO, NO_2, NO_x, CO) ve meteorolojik parametrelerden (sıcaklık, rüzgâr hızı, rüzgâr yönü ve toplam yağış) 4 yıllık (2016, 2017, 2018, 2019) veri tabanı oluşturulmuştur. Hava kalitesi indeksi değerleri de ele alınarak verilerin zamansal değerlendirmesi yapılmış ve birbirleri ile olan ilişkisi incelenmiştir. Ayrıca 2020 yılında COVID-19 pandemisi kaynaklı kısıtlamaların hava kalitesine olan etkileri araştırılmıştır. Çerkezköy ile benzer şehirleşme ve sanayileşmeye sahip bölgeler ile şehirleşme ve sanayiden uzak bölgeler karşılaştırılarak, kirletici kaynakları ve nedenleri belirlenmeye çalışılmıştır.

Çalışmanın ikinci bölümünde 6 farklı makine öğrenmesi yöntemi kullanılarak, "R" yazılım ortamında, PM_{10} ve $PM_{2.5}$ konsantrasyonları modellenmiş ve tahmin edilmiştir. Kirletici veriler, meteorolojik veriler, kirletici ve meteorolojik veriler olmak üzere 3 farklı veri seti hazırlanarak modellemede kullanılmış ve farklı sonuçlar elde edilmiştir. Tahmin sonuçları R, MAE ve RMSE istatistiksel performans parametreleri kullanılarak karşılaştırılmıştır. PM_{10} ve $PM_{2.5}$ tahmini için ANFIS metodunun diğer metotlardan daha başarılı olduğu görülmüştür.

Haziran 2022 , 120 sayfa.

Anahtar kelimeler: Hava kirliliği, partikül madde, hava kalitesi indeksi, yapay zeka, makine öğrenmesi

ABSTRACT

Ph.D. THESIS

INVESTIGATION of AIR QUALITY and MODELING with TRAINING ALGORITHMS; a CASE STUDY for ÇERKEZKÖY

Hüseyin ÖZEL

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Environmental Engineering

Programme of Environmental Engineering

Supervisor: Prof. Dr. Hüseyin Kurtuluş ÖZCAN

Co-Supervisor: Assist. Prof. Dr. Pınar CİHAN

Pollutants that cause air pollution continue to be released into the atmosphere in increasing amounts day by day. Various health problems arise in the short and long term due to air pollution in densely populated areas. In order to keep the air quality high at the city scale, it is necessary to monitor the air pollution with measurements and to implement the necessary preventive policies based on the results. In determining the air quality, air pollutants can be measured using mathematical models, as well as the measurement results of pollutants are estimated with the development of technology and artificial intelligence models.

In this study, it is aimed to estimate the concentrations of PM_{10} and $PM_{2.5}$ pollutants by analyzing the temporal variation of PM_{10} and $PM_{2.5}$ pollutants in Çerkezköy location, where urbanization and industry are intertwined, using machine learning methods such as ANFIS (Adaptive Neuro Fuzzy Inference System), SVR (Support Vector Regression), CART

(Classification and Regression Trees), RF (Random Forest), KNN (K-Nearest Neighbor) and ELM (Extreme Learning Machine).

For this purpose; In the first part of the study, a 4-year (2016, 2017, 2018, 2019) database of air pollutants (PM_{10}, $PM_{2.5}$, SO_2, NO, NO_2, NO_x, CO) and meteorological parameters (temperature, wind speed, wind direction and total precipitation) was created. By considering the air quality index values, the temporal evaluation of the data was made and their relationship with each other was examined. In addition, the effects of restrictions caused by the COVID-19 pandemic on air quality in 2020 were investigated. By comparing the regions with similar urbanization and industrialization with Çerkezköy and the regions far from urbanization and industry, the sources and causes of pollutants were tried to be determined.

In the second part of the study, PM_{10} and $PM_{2.5}$ concentrations were modeled and estimated using 6 different machine learning methods in the "R" software environment. Three different data sets, namely pollutant data, meteorological data, pollutant and meteorological data, were prepared and used in modeling and different results were obtained. The estimation results were compared using the statistical performance parameters R, MAE and RMSE. It was seen that the ANFIS method was more successful than other methods for PM_{10} and $PM_{2.5}$ prediction.

June 2022, 120 pages.

Keywords: Air pollution, particulate matter, air quality index, artificial intelligence, machine learning

1. GİRİŞ

2018 yılında yayımlanan Birleşmiş Milletler (BM) raporuna göre, küresel kentleşme %55 oranına yükselmiştir (BM, 2019). Kentleşmenin artışında sanayileşme büyük rol oynamaktadır ve sanayi ile kentleşmenin iç içe olduğu yerleşim yerleri aynı zamanda ulaşımda yoğunluğa neden olmaktadır. Hızla gelişen sanayileşme ve kentleşme aynı zamanda enerji tüketimini arttırırken sonucunda da küresel ölçekte hava kirliliğini oluşturmaktadır (Li ve diğ., 2021). Kentlerde ısınma amaçlı fosil yakıtların kullanımı, sanayi kaynaklı hava kirliliği ve ulaşımdan kaynaklı hava kirliğinin birleşmesi sonucunda yüksek konsantrasyonda partikül madde (PM), kükürt dioksit (SO_2), azot dioksit (NO_2), ozon (O_3) ve karbon monoksit (CO) atmosfere salınmakta, canlı ve cansız varlığını olumsuz etkileyecek ölçüde hava kirliliğine neden olmaktadır.

Atmosferdeki partikül madde kirliliği, özellikle 10 μm'nin altındaki kirletici partiküllerin (PM_{10}) solunum yoluyla ilişkili olumsuz sağlık etkileri dünya çapında endişe yaratmaktadır (Rai, 2016). Düşük veya yüksek gelirli ülke ayrımı olmaksızın, dış ortam hava kirliliği herkesi etkileyen önemli bir çevre sağlığı sorunudur. Buna bağlı olarak Dünya çapında ortam hava kalitesini ölçmek ve takip etmek için solunabilir parçacıklar olarak ifade edilen partikül maddeler; PM_{10} ve $PM_{2.5}$ önemli birer indikatör olmakta, mevzuat ve direktifler kapsamında limit değerleri belirlenmektedir. Tüm etkiler göz önünde bulundurulduğunda özellikle endüstriyel ve kentsel bölgelerde PM seviyesi önem arz etmektedir. Atmosferde bulunan partikül madde seviyesi genel olarak ülkeler arası farklılık göstermektedir; ABD ve Avrupa ülkelerinde bu değerler 15-60 $\mu g/m^3$ iken Asya ülkelerinde 35-220 $\mu g/m^3$ seviyelerine çıkmaktadır (DSÖ, 2006).

Yapılan birçok çalışmada atmosferdeki PM konsantrasyonunun hastaneye yatma, erken ölüm ve özellikle çocuklarda yüksek oranda sağlık sorunlarına neden olduğu görülmüştür (Bell ve diğ., 2007; Goldizen ve diğ., 2016; Mutlu ve diğ. 2018; Norbäck ve diğ., 2019). Partikül maddelerin yanı sıra SO_2, NO_2, O_3 ve CO atmosferde yüksek oranda bulunması sonucu insan sağlığını olumsuz etkileyen ve ölüme neden olan hava kirletici parametrelerdir (Guo ve diğ., 2021; Yun ve diğ., 2015; Temam ve diğ., 2017; Liu ve diğ., 2019; Jerrett ve diğ., 2009; Hampson ve diğ., 2012; Bahrami Asl ve diğ., 2018).

Hava kirliliğinin hem çevre hem de insan sağlığı için bir tehdit oluşturduğu iyi bilinmektedir. Her yıl milyonlarca ton toksik kirleticinin havaya salındığı tahmin edilmektedir. Dünya nüfusunun yaklaşık %91'i Dünya Sağlık Örgütü'nün (DSÖ) belirlemiş olduğu sınır değerlerin üzerinde kirletici konsantrasyonuna sahip havayı solumaktadır. Hava kirliliği tek başına yılda yaklaşık 7 milyon ölüme veya tüm ölümlerin sekizinde birine neden olarak sağlık için en büyük küresel riskler arasında yer almaktadır (DSÖ, 2020).

Teknolojinin gelişimi ile eğitilebilir algoritmaların mühendislik alanında kullanımı yaygınlaşmıştır. Hava kalitesinin tahmininde yapay zekâ modelleri ve makine öğrenmesi teknikleri kullanılarak başarılı tahminler yapılmaktadır. Bozdağ ve arkadaşları (2020) PM_{10} araştırmalarında birden fazla makine öğrenmesi tekniği kullanarak %56-61 aralığında doğruluk tespit ederken, Bhardwaj ve Pruthi (2020) sadece bir teknik üzerine yoğunlaşmış ve %70 doğruluk ile $PM_{2.5}$ tahmini yapmıştır. Birçok çalışmada ise farklı hava kirletici parametreler, farklı meteorolojik veriler ve Hava Kalitesi İndeksi (HKİ) veri seti olarak kullanılırken farklı makine öğrenmesi teknikleri uygulamıştır (Yoo ve diğ., 2019; Lovric ve diğ., 2021; Bisht ve Seeja, 2018; Zhai ve Chen, 2018; Du ve diğ., 2020; Ausati ve Amanolhali, 2016).

Bu çalışmanın amacı; kentle iç içe olan bir sanayi bölgesinde hava kalitesinin uzun süreli incelenmesi, PM_{10} ve $PM_{2.5}$ bileşenlerinin farklı eğitilebilir algoritmalar ile tahmin edilmesidir. Bu amaçla çalışmanın birinci aşamasında hava kirletici konsantrasyonları ve meteorolojik verilerden oluşan bir veri tabanı oluşturulup hava kalitesi indeksi değerleride ele alınarak hava kalitesinin zamansal analizi yapılmıştır. Ayrıca bu aşamada COVID-19 pandemisinin hava kalitesi üzerine etkisini belirlemek için sokağa çıkma kısıtlamalarının uygulandığı dönem ile geçmiş dönemler karşılaştırılarak pandemi sürecinin hava kalitesi üzerine olası etkileri belirlenmiştir. Çalışmanın ikinci aşamasında oluşturulan veri tabanı kullanılarak 6 farklı makine öğrenmesi tekniği ile PM_{10} ve $PM_{2.5}$ konsantrasyonları tahmin edilmiştir. Çalışmanın son aşamasında ise modellerin tahmin performansları istatistiksel olarak karşılaştırılmış olup bu tezde kullanılan veri seti için en başarılı tahminde bulunan makine öğrenmesi modeli belirlenmiştir.

2. KAVRAMSAL ÇERÇEVE

2.1. HAVA KİRLİLİĞİ

Hava, yerküremizin çevresini saran atmosfer adı verilen gaz tabakasından oluşan bir ortamdır. Atmosferin yoğunluğu yer çekimi kuvveti etkisi sonucu yer kabuğuna yakın bölgede daha fazladır (Müezzinoğlu, 2000). Hava kirliliği ve atmosfer üzerindeki çalışmaları anlamak için öncelikle atmosferin bileşenlerini iyi bilmek gerekir. Atmosferin majör, minör ve eser olmak üzere üç bileşeni vardır. Zemin seviyesindeki kuru hava, şu bileşenlere sahiptir; majör bileşenler Azot (%78,09), Oksijen (%20,94), su buharı (%0,1); minör bileşenler Argon (%0,9), Karbondioksit (%0,032); eser bileşenler Neon (%0,0018), Helyum (%0,0005), Metan (%0,0002) ve diğer eser bileşenler (De ve De, 2009).

Yer seviyesinden 11-20 kilometre aralığındaki yükseklikte Tropopoz yer alır. Tropopoz ozon bileşikleri açısından zengin bir katman oluşturarak güneşten dünyaya ulaşan morötesi (UV) ışınların zararlı etkilerini filtre ederek engeller. Söz konusu etkisinden dolayı Tropopoz insan sağlığını ve diğer canlıları güneş ışınlarının ölümcül etkilerinden korumuş olur. Aksi halde insan ve hayvanlarda göz bozukluğundan cilt kanserine kadar farklı hastalıklar oluşabileceği gibi ekosistem dengesinde bozukluk görülebilirdi. Sınır katman olan Tropopoz ile yer seviyesi arasında kalan atmosfer tabakası Troposfer olarak adlandırılır. İnsanlarla birlikte tüm canlı ve cansız varlıkların var olduğu atmosfer tabakası Troposferdir, bu nedenle bilimsel araştırmalarda atmosfer tabakaları içinde en önemli yere sahiptir (Müezzinoğlu, 2000).

Birleşik Devletler Çevre Koruma Ajansı (US EPA - United States Environmental Protection Agency) hava kirliliğini, kirletici maddelerin dağılmadan insan sağlığına veya refahına zarar verecek veya başka zararlı çevresel etkiler oluşturacak şekilde havada var olması olarak tanımlamıştır (EPA, 1992). Bu zararlı çevresel etkiler; kirletici deşarj eden bir kaynak, kirleticilerin taşınımı ve alıcı ortamın bir arada olması halinde gerçekleşir. Kaynağın konumu, tipi ve şiddeti salınan kirleticinin karakterini ve etkisini belirlemede önemlidir. Bölgenin topografyası, meteorolojik koşulları ve klimatolojisine bağlı olarak kirleticilerin taşınımı gerçekleşir. Kirleticilerin kaynaktan çıkarak alıcı ortama ulaşmasına tüm bu faktörler etkilidir. Alıcı diye tabir edilen ise insan, hayvan, bitki ve cansızlardır (Schnelle ve diğ., 2015).

Hava kirliliğinin olumsuz etkilerinin tespit edilebilmesi için bir alıcı ortamın olması ve kirleticinin bu alıcı ortama temas ederek istenmeyen bir etkinin oluşması gerekir. Hava kirliliği etkilerinin belirlenmesi için aşağıdaki özelliklerin bilinmesi gerekir (Vallero, 2008).

- Alıcı ortamdaki kirleticilerin fiziksel, kimyasal, biyolojik ve doğal özellikleri
- Alıcı ortam özellikleri (insan, bitki, ekosistem, nesli tükenmekte olan türler vb.)
- Alıcı ortam insan ise mevcut sağlık durumu
- Ekosistem şartları
- Kirleticilerin fiziksel formu ve kimyasal kompozisyonu
- Kirleticilerin saf veya karışım halinde oluşu
- Temas şekli (hava, cilt, gıda vb.)

Hava kirliliğinden kaynaklanan zararın büyüklüğünü ve derecesini tanımlamak için yukarıda belirtilen bilgiler gerekmektedir.

Hava kirletici olarak ele alınabilecek çeşitli kirleticiler vardır. Bunlar; toz, gaz, sis, duman, gaz halindeki Hidrojen florür, kötü koku ve buhardır (Kothari ve diğ, 2016). İnsan ve çevre sağlığını olumsuz etkileyen başlıca hava kirleticiler ise şunlardır (De ve De, 2009);

- Partikül madde (PM)
- Azot oksitler (NO_x)
- Kükürt dioksit (SO_2)
- Karbon monoksit (CO)
- Hidrokarbonlar (HC)

Bu beş kirletici birincil kirleticiler olarak adlandırılmaktadır. Birincil kirleticiler küresel hava kirliliğinin yaklaşık %90'ını oluşturmaktadır (Kothari ve diğ., 2016).

2.2. HAVA KİRLİLİĞİ KAYNAKLARI

Doğal ortamdaki hava "saf" değildir ve toz, bakteri, polen, insan sağlığına ve çevreye zararlı kirletici gazlar gibi diğer maddeleri içerir. Hava; kül, toz, kükürt ve diğer gazları açığa çıkaran volkanik püskürmeler gibi doğal nedenlerle veya bazen yıldırımın neden olduğu orman yangınlarıyla kirlenebilir.

Hava kirliliği kaynakları doğal ve insan faaliyetleri olmak üzere iki başlık altında sınıflandırılabilir. Doğal kaynaklı kirleticiler evrimsel ekosistemin bir parçasıdır, dolayısıyla yaşam için tehlikeli bir seviyeye ulaşmazlar. Başlıca doğal hava kirliliği kaynakları volkanik faaliyetler, orman yangınları, toz fırtınaları, çiçek polenleridir. Hava kirliliğine neden olan başlıca insan faaliyetleri ise motorlu taşıtların emisyonları, endüstriyel üretim faaliyetleri, termal güç üretim tesisleri, hava taşımacılığı, anız yangınları, madencilik, çöp yakma tesisleri, katı atık bertaraf tesisleri, petrol rafineleri ve demir çelik üretim tesisleridir (Kothari ve diğ., 2016). Ayrıca hava kirliliğinin niteliği, kaynağa, emisyon oranına, güneş ışığı ve rüzgâr koşullarına bağlı olarak büyük ölçüde değişiklik gösterir (Hamanaka ve diğ., 2018).

2.3. HAVA KİRLETİCİLER

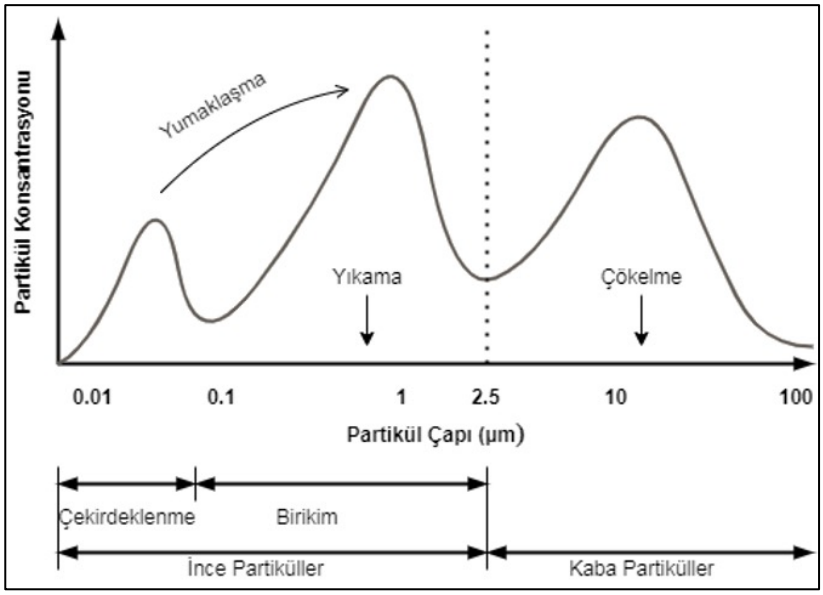
2.3.1. Partikül Madde (PM)

Atmosferik partikül madde (PM) atmosfer ortamında katı ve sıvı tanelerin kompleks bir yapısı olarak tanımlanabilir. Partikül maddeler doğal ve antropojenik yollarla atmosfere karışabilir. Ayrıca kimyasal reaksiyonlar sonucu da atmosferde oluşabilir. Atmosferde yaklaşık 0,1 ppm yer kaplayan partikül maddeler birçok atmosferik olayda önemli yere sahiptir. Bulut oluşumu ve özelliklerini etkiler, atmosferde kimyasal reaksiyonları katalizler ve atmosferin optik yapısını değiştirebilir. Atmosferik radyoaktivite küresel iklim üzerine önemli etki etmektedir, bu nedenle partikül maddelerin atmosfer ortamındaki varlığı ayrı bir öneme sahiptir. Hava kirliliğinin partikül madde bileşenleri, karbonlu partiküllerle ilişkili adsorbe organik kimyasallar ve reaktif metallerden oluşur. PM'nin yaygın bileşenleri arasında nitratlar, sülfatlar, polisiklik aromatik hidrokarbonlar, endotoksinler, demir, bakır, nikel, çinko ve vanadyum gibi metaller bulunur (Hamanaka ve diğ., 2018).

PM, partikül boyutuna göre kaba (PM_{10}, çap <10 μm), ince ($PM_{2.5}$, çap <2,5 μm) ve ultra ince ($PM_{0.1}$, çap <0,1μm) olarak alt sınıflandırılmıştır. Kaba partiküller, çok sayıda doğal ve endüstriyel kaynaktan türetilir ve genellikle üst bronşların ötesine geçmez. İnce ve ultra ince partiküller, fosil yakıtların yanmasıyla üretilir solunum sistemindeki küçük hava kanallarına ve alveollere nüfuz ettikçe kaba partiküllerden daha büyük bir sağlık tehdidi oluşturur. Partiküllerin organik ve metal bileşenleri lokasyona göre değişirken, $PM_{2.5}$ seviyeleri, lokasyondan bağımsız olarak negatif kardiyovasküler sonuçlarla tutarlı bir şekilde ilişkilendirilmiştir (Hamanaka ve diğ., 2018).

Devletlerin hazırlamış olduğu mevzuat veya kurumların hazırlamış olduğu standartlarda partikül madde kirliliği kontrolü 2,5 μm'den ($PM_{2.5}$) ve 10 μm'den (PM_{10}) küçük parçacıkların kütle konsantrasyonu ile takip edilir. PM_{10} genel olarak toplam PM_{10} kütlesinin %50-70'ini temsil eden $PM_{2.5}$ ile ince partikülleri ve kaba partikül fraksiyonunu içerir. Ultra ince parçacıklar da $PM_{2.5}$ ve PM_{10}'a dahil edilir, ancak tipik olarak kütlesel olarak ihmal edilebilir bir fraksiyona katkıda bulunurken, parçacık sayısı olarak baskın fraksiyondadırlar. Toprağın ve yol tozunun rüzgâr veya hareket eden araçların yanı sıra inşaat işleri ve endüstriyel emisyonlar tarafından yeniden süspanse edilmesi kaba parçacıkların oluşumuna (PM_{10}) neden olur. Partikül madde emisyon kaynaklarının başında motorlu karayolu trafiği, enerji santralleri ile ısı amaçlı petrol, kömür veya odun kullanan endüstriler ve konutlar gelmektedir. Bu yanma süreçleri, karbon siyahı, geçiş metalleri, karmaşık organik moleküller, sülfat ve nitrattan oluşan ince partiküller ($PM_{2.5}$) ile sonuçlanır. Nihai bileşenler ise atmosferde uçucu organik bileşikler, SO_2 ve NO_2'den oluşur. İnce partiküller büyük mesafeler (>100 km) kat edebilir ve bu durum geniş alanlarda PM konsantrasyonu artışına sebep olabilir (Newby ve diğ., 2015).

Partikül madde, boyut ve bileşim bakımından farklılık gösteren çok çeşitli kaynaklardan elde edilen parçacıklardan oluşur. Partiküller genellikle üç ana boyut grubuna ayrılır ve Şekil 2.1'de çaplarına göre partikül maddenin değişimi gösterilmiştir.



Şekil 2.1: Partikül maddenin kökeni ve özellikleri (Heil, 1998).

$PM_{2.5}$, küçük boyutları sayesinde saatler ve haftalar süresince havada sabit kalabilir. Yüksek konsantrasyonlu kararlı $PM_{2.5}$, puslu bir hava oluşumuna neden olur. Partikül boyutları ile

görünür ışık dalga boyları arasındaki benzerlik nedeniyle görünür ışığı dağıtabilir ve görünürlüğü azaltabilir. Çok kirli havadaki $PM_{2.5}$ partikülleri, tipik olarak karbon türevli maddeler (CO_2, CO vb.), silikatlar (SiO_3^{2-}), kükürt dioksit (SO_2^{2-}), sülfatlar (SO_4^{2-}), silisyum dioksit (SiO_2), nitratlar (NO_3^-), amonyum (NH_3), klorür ve biyolojik maddeler (bakteri, virüsler vb.) içeren bileşikler şeklinde olabilir (Wang ve diğ., 2018).

Partikül maddenin olumsuz etkisi aerodinamik çapıyla ilgilidir. Aerodinamik çapı 2,5 μm ($PM_{2.5}$) veya daha küçük olan ince partikül madde, üst solunum yolunun savunma mekanizmalarını aşarak önce pulmoner alveollere ve ardından sistemik dolaşıma ulaşarak tüm vücut sistemlerini etkiler (Lee, 2014).

Partikül maddelerin aerosol formunda solunum yoluyla alınması olumsuz sağlık sorunlarına neden olmaktadır. Dış ortam ve iç ortam hava kirliliği, kardiyovasküler hastalıklar, felç, solunum yolu hastalıkları ve kanser gibi çeşitli sağlık sorunlarına yol açan önemli bir çevresel risk faktörüdür. Hava kirliliği 2016 yılında dünya genelinde yaklaşık 7 milyon ölüme neden olmuştur. Bu ölümlerin 4 milyonu hava kirliliği açısından en yüksek ölüm oranına sahip Sahra altı Afrika'da, Asya ve Okyanusya'da (Avustralya ve Yeni Zelanda hariç) görülmüştür (DSÖ, 2021).

Küresel olarak, 2016 yılında, $PM_{2.5}$ konsantrasyonu 34,7 $\mu g/m^3$ (kentsel ölçekte 31,2 $\mu g/m^3$) idi. Bu durum $PM_{2.5}$ kirliliğinin 10 $\mu g/m^3$ olan yıllık ortalama DSÖ hava kalitesi güvenlik standardından birkaç kat daha yüksek olduğunu göstermektedir. Bölgesel ölçekte incelendiğinde yıllık ortalama en düşük $PM_{2.5}$ konsantrasyonu Amerika Kıtasında (11,6 $\mu g/m^3$) ve Avrupa Kıtasında (12,8 $\mu g/m^3$) en yüksek konsantrasyon ise Asya Kıtasının Güneydoğu Bölümünde (54,3 $\mu g/m^3$) ve Doğu Akdeniz Bölgesi'nde (51,1 $\mu g/m^3$) ölçülmüştür (DSÖ, 2021).

Ayrıca partikül madde ikincil kirletici olarak da hava kirliliğine ve çevreye etki etmektedir. Görüş mesafesinde azalma, asit yağmurları oluşumu ile taş ve diğer yapı malzemelerine hasar bırakması ikincil kirletici olarak yarattığı olumsuz çevresel etkilerdir (Mines ve Richard, 2014).

2.3.2. Azot Oksitler (NO_x)

Genel tabir olarak NO_x olarak adlandırılan azot oksit bileşikleri; N_2O, NO, N_2O_3 ve N_2O_5 gibi çeşitli azot oksit formlarındadır. Bu bileşikler kömür ve petrol gibi fosil yakıtları kullanan motorlu taşıtlar ve termik enerji üretim santralleri tarafından salınır (Kothari ve diğ., 2016).

Azot oksitler (NO_x), azot monoksit (NO) ve azot dioksitten (NO_2) oluşur. Azot monoksit (NO) bileşiği renksiz ve kokusuz bir gazdır, ancak azot dioksit (NO_2) bileşiği kırmızımsı kahverengi renge ve keskin bir kokuya sahiptir (De ve De, 2009).

NO ve NO_2 oluşumu kimyasal reaksiyon denklemleri şu şekildedir;

$$N_2 + O_2 \xleftrightarrow{1210°C-1765°C} 2NO \quad (2.1)$$

$$2NO + O_2 \longleftrightarrow 2NO_2 \quad (2.2)$$

N_2-2NO-$2NO_2$ reaksiyonları (2.1 ve 2.2 numaralı denklemler) içten yanmalı otomobil motorlarının içinde meydana gelir ve böylece egzoz gazları NO_x açısından oldukça zengin olur (De ve De, 2009).

Ayrıca azot oksitler, tüm canlı organizmalar için daha tehlikeli olan ikincil hava kirleticileri üretme kaynağı olarak önemli bir rol oynamaktadır. Havada NO_x, doğal süreçlerle nitrik aside (HNO_3) dönüşür ve asit yağmuru olarak yer yüzüne iner (Kothari ve diğ., 2016; De ve De, 2009).

Atmosferde doğal yollarla NO_x'in nitrik aside (HNO_3) dönüşmesi reaksiyonu şu şekildedir;

$$NO_2 + O_3 \xrightarrow[(Ozon)]{} NO_3 + O_2 \quad (2.3)$$

$$NO_3 + NO_2 \longrightarrow N_2O_5 \quad (2.4)$$

$$N_2O_5 + H_2O \longrightarrow 2HNO_3 \quad (2.4)$$

Atmosferde yarılanma ömürleri düşük olan azot oksitlerin dünya atmosferinde 1 ppb'den daha az derişime sahip olmaları beklenir. Fakat kentsel atmosferde 40-80 ppb ve hatta 300-1400 ppb derişimlerine kadar görülebilmektedir (Boşgelmez ve diğ., 2000; Müezzinoğlu, 2000).

Azot oksitlerden biri olan azot dioksit zehirli bir gazdır. NO_2 yüksek konsantrasyonlarda ciğerlerde ödem ve kanamalara neden olur, kısa süreli maruziyet sonucu solunum ve kardiyovasküler hastalıklara neden olabilir ve ayrıca bitki örtüsünde de doğrudan zehir etkisi yaratır (Müezzinoğlu 2000).

2.3.3. Kükürt Dioksit (SO_2)

Kükürt dioksit (SO_2) kükürt oksit gazlarının (SO_x) bir parçası olan renksiz, parlama ve yanıcı özelliği olmayan bir gazdır. Kükürt, kömür ve petrol gibi fosil yakıtlar ile demir, alüminyum,

çinko gibi ağır metal madeni cevherlerinde yüksek oranda bulunur. Bu nedenle fosil yakıtların yakılması, işlenmesi, maden zenginleştirme prosesleri esnasında SO_x emisyonları oluşur. Atmosferdeki SO_2 emisyonunun en önemli kaynağı elektrik üretim faaliyetlerinde kullanılan fosil yakıtlardır. Yakıt olarak kömür kullanan termik santraller SO_2 salınımında en çok etkiye sahiptir.

Çimento fabrikaları, petrol rafineleri, metalürji endüstrisi ve benzeri ham madde işleyip üretim yapan sanayi tesisleri SO_2 emisyonlarında önemli bir yere sahiptir. Isınma amaçlı kentsel alanlarda kullanılan sıvı ve katı formlu fosil yakıtların yanı sıra volkanik aktiviteler ve orman yangıları da SO_2 emisyonlarına neden olur. Kömürlü termik santraller ve diğer kömür kullanan endüstriler SO_x kirliliğinin %33'ünün oluşum nedenidir ve insan kaynaklıdır. Geri kalan %67 oranındaki SO_x kirliliğinin kaynağı ise doğal kaynaklardır (De ve De, 2009).

Atmosferik kirleticilerin bir kısmı deşarj edildikleri halde bir değişime uğramadan atmosferde bulunurlar ve birincil kirleticiler olarak bilinirler. Azot oksitler ve kükürt oksitler atmosferde bulunan hidrojen klorürler ve ozon gibi oksitleyici kirleticiler ile oluşturdukları kükürt dioksit (SO_2) ve azot oksit (NO_x) birleşikleri asit yağmurlarına neden olmaktadır. Ayrıca oluşan nihai kirleticiler ikincil kirleticiler olarak adlandırılır. İkincil kirletici olan sülfürik asit (H_2SO_4) oluşum reaksiyonları ise şu şekildedir (De ve De, 2009);

$$S + O_2 \longrightarrow SO_2 \tag{2.5}$$

$$2SO_2 + O_2 \longrightarrow 2SO_3 \tag{2.6}$$

$$SO_2 + O_3 \longrightarrow SO_3 + O_2 \quad \overset{\curvearrowleft H_2O \curvearrowright}{H_2SO_4} \longrightarrow (H_2SO_4)_n \tag{2.7}$$

$$SO_2 + {}^1\!/_2\, O_2 \longrightarrow SO_3 \longrightarrow H_2SO_4 \longrightarrow (H_2SO_4)_n \tag{2.8}$$

Oluşan asidik bileşikler emisyon kaynağından yüzlerce kilometre uzakta meydana gelebilir, çünkü bu bileşikler, bölgedeki hâkim rüzgarlar tarafından uzun mesafelere taşınabilir. Yeryüzünün yüzeyinde birikme, yağmur damlacıkları ile reaksiyondan sıvı formda veya asidik malzemelerin toz partiküllerine adsorpsiyonu yoluyla kuru biriktirme şeklinde var olabilir. Asit yağmuru, göllerin ve akarsuların asiditesinin artmasına neden olabilir. Yüksek rakımlardaki ağaçların zarar görmesine katkıda bulunabilir. Toprağı daha asidik hale getirerek hassas bitki ve orman oluşumuna engel olabilir. Ayrıca asit yağmuru yapı malzemelerinin ve boyaların

çürümesini hızlandırır. Bu durum, bina sahipleri ve yapısal altyapı üzerinde ekonomik bir etki yaratır. Ayrıca heykellerin ve diğer sanat eserlerinin bozulması yoluyla olumsuz kültürel etki potansiyeli de vardır (De ve De 2009; Mines ve Richard, 2014).

Atmosferde sık görülen SO_2 suda çözünürlüğü yüksek olduğundan kolaylıkla kan dolaşımına girebilmektedir. Asidik etkiye sahip olan SO_2 üst solunum yolları ve mukozayı tahriş etmekte, faranjit, astım, bronşit gibi enfeksiyonlara neden olmaktadır. Partikül madde ile birleşen SO_2 daha yüksek konsantrasyonlarda üst solunum yollarını etkileyerek daha zarar verici hale gelir (Müezinoğlu, 2000).

2.3.4. Karbon Monoksit (CO)

Karbon monoksit (CO), renksiz, kokusuz ve tatsız bir gazdır, tahriş edici değildir fakat boğucu ve yüksek konsantrasyonda yanıcılık özelliğine sahiptir (DiLoreto ve Corcoran, 2012).

Kömür, odun ve doğalgaz gibi fosil yakıtların (Hidrokarbonların) oksijence eksik ortamda tamamen yanmaması sonucu oluşur. Her yıl 275 milyon tonu insan kaynaklı ve 75 milyon tonu doğal kaynaklı olmak üzere 350 milyon ton CO atmosfere salınmaktadır. İçten yanmalı motora sahip taşıtlarda fosil yakıtın yanması en büyük CO kaynağıdır ve taşımacılık sektörü atmosfere salınan CO emisyonunun %70'ini oluşturmaktadır. Doğal süreçler sonucu atmosferdeki CO'nun zararlı olmayan CO_2'ye dönüşmesi onu kalıcı bir kirletici olmaktan çıkarmaktadır (Kothari ve diğ., 2016; De ve De, 2009).

Karbon monoksit (CO) oluşumunun kimyasal reaksiyonları şu şekildedir;

Karbon içeren bileşiklerin veya fosil yakıtların eksik yanması ile;

$$2C + O_2 \rightarrow 2CO \tag{2.9}$$

Karbon dioksit ve karbonlu maddelerin yüksek sıcaklıkta yanması ile;

$$CO_2 + C \rightarrow 2CO \tag{2.10}$$

Karbon dioksitin yüksek sıcaklıkta ayrışması ile;

$$CO_2 \leftrightarrow CO + O \tag{2.11}$$

Orman yangını veya volkanik püskürmeler de karbon monoksit oluşumuna neden olabilir. Doğal atmosferdeki ortalama karbon monoksit konsantrasyonu 0,1 ppm, iç ortamdaki

konsantrasyon ise 0,5-5 ppm'dir. Ancak evlerde kullanılan hava girişi yetersiz sobalar, ev içindeki CO konsantrasyonunu 30 ppm'in üzerine çıkarabilir (DiLoreto ve Corcoran, 2012).

İnsan solunum yollarına giren karbon monoksit kanın alyuvarlarındaki hemoglobinin oksijen yerine karbon monoksit ile tercihli olarak bir kompleks olan karboksihemoglobin (CO-Hb) oluşturması sonucu dokulara oksijen taşınımını engellemiş olur. Ayrıca karboksihemoglobin, dokulara taşınabilmiş olan oksihemoglobinin (O_2-Hb) hücre içinde oksijeni serbest hale çevirmesini zorlaştırdığı bilinmektedir (Müezzinoğlu, 2000).

Kanda CO-Hb oluşum hızı O_2-Hb oluşum hızından 210 kat daha fazladır ve bu da havada bulunan 209000 ppm oksijen varlığının en az 1/200-1/250 oranında CO derişimine ulaşıldığında O_2-Hb yerine tamamen CO-Hb oluşacağı anlamına gelir. CO olarak insan öldürebilen tehlikeli sınır değer 750-1000 ppm'e tekabül etmektedir (Müezzinoğlu, 2000).

200 ppm civarındaki CO konsantrasyonu 2-3 saat sonra baş ağrısına neden olur ve 2000 ppm üzerindeki konsantrasyon 1 saat sonra ölüme neden olur. Çok sık sigara içenlerde %10-15 karboksihemoglobin (CO-Hb) düzeyine ulaşan kronik zehirlenme durumu görülebilir. CO'nun verdiği hasar ortamdaki bağıl CO ve oksijen konsantrasyonuna, maruz kalma süresine, metabolik hıza ve hemoglobin konsantrasyonuna bağlıdır (DiLoreto ve Corcoran, 2012).

2.3.5. Hidrokarbonlar (HC)

Doğal süreçler, özellikle ağaçlar havada büyük miktarlarda hidrokarbon yaymaktadır. Metan (CH_4) önemli bir hidrokarbondur. Organik maddenin su tortullarında ve toprakta anaerobik bozunmasıyla oluşan bakteriler tarafından büyük miktarlarda üretilmektedir. İnsani faaliyetler sonucu üretilen hidrokarbonların en önemli kaynağı ise otomobillerdir. Organik maddenin (CH_2O) bakteriler tarafından karbondioksit ve metana dönüşüm reaksiyonu şu şekildedir (De ve De, 2009);

$$2(CH_2O) \xrightarrow{\text{Bakteri}} CO_2 \uparrow + CH_4 \uparrow \qquad (2.12)$$

Ozon varlığında karbon monoksit, azot oksitler ve hidrokarbon fotokimyasal reaksiyonlara (güneş ışığının varlığında) katılır. İlk adımda serbest radikal R C$^{\bullet}H_2$'nin üretildiği bir zincirleme reaksiyon ilerler. Oluşan diğer serbest radikaller şunlardır; R $CH_2{}^{\bullet}O_2$ formundaki diğer serbest radikal ikinci adımda oksijen ve R CH_2O ile reaksiyona girer. Üçüncü adımda azot oksit ile R $CH_2{}^{\bullet}O$ reaksiyona girer. Dördüncü adımda H $^{\bullet}O_2$ oksijen ile reaksiyona girer. Stabil olan aldehit R CHO bu adımın yan ürünüdür. Beşinci adımda azot oksit reaksiyonu sonucu H$^{\bullet}O$ oluşur (azot

dioksit bu adımdaki diğer üründür). Son olarak başlangıç serbest radikali $RC^{\bullet}H_2$ hidrokarbon ve R CH_3 ile reaksiyonla yeniden oluşur, böylece zincir reaksiyon devam eder.

Zincir reaksiyonundaki zararlı ürünler NO_2 ve aldehit R CHO'dur. Aldehit R CHO ile başlayan bir başka reaksiyon sonucu güçlü bir göz tahriş edici olan zararlı bir son ürün olan peroksi asil nitrat (PAN) oluşur. Bu reaksiyonlar gözleri ve ciğerleri tahriş eden ve ayrıca bitkilerde ciddi hasara neden olan kahverengi puslu dumanlarla karakterize edilen fotokimyasal duman oluşumuna yol açar (De ve De, 2009).

2.4. HAVA KALİTESİ STANDARTLARI

Türkiye Cumhuriyeti Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'nın (ÇŞB) yayımlamış olduğu 2018 tarihli Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği'ne göre kirleticiler için belirlenen sınır değerler Tablo 2.1'de verilmiştir (ÇŞB, 2008).

Tablo 2.1: Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği'ne göre kirleticilerin sınır değerleri.

Kirletici	Ortalama Süre	Sınır Değer
SO_2	**Saatlik** • İnsan sağlığının korunması için • Bir yılda 24 defadan fazla aşılmaz	350 µg/m^3
	24 Saatlik • İnsan sağlığının korunması için • Bir yılda 3 defadan fazla aşılmaz	125 µg/m^3
	Yıllık ve Kış Dönemi • 1 Ekim'den 31 Mart'a kadar, ekosistemin korunması için	20 µg/m^3
NO_2	**Saatlik** • İnsan sağlığının korunması için • Bir yılda 18 defadan fazla aşılmaz	200 µg/m^3
	Yıllık • İnsan sağlığının korunması için	40 µg/m^3
NO_x	**Yıllık** • Vejetasyonun korunması için	30 µg/m^3
PM_{10}	**24 Saatlik** • İnsan sağlığının korunması için • Bir yılda 35 defadan fazla aşılmaz	50 µg/m^3
	Yıllık • İnsan sağlığının korunması için	40 µg/m^3
CO	**Maksimum Günlük 8 Saatlik Ortalama** • İnsan sağlığının korunması için	10.000 µg/m^3
$PM_{2.5}$	Kirletici için Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliğinde bilgilendirme ve uyarı eşiği ile hedef değer ve uzun vadeli hedef bulunmaktadır.	

Güncellenen mevzuatlarla Türkiye'de 2009 yılından başlayarak hava kirleticileri için belirlenen sınır değerler düşürülmüştür. 2009 yılında PM_{10} için belirlenen limit değer günlük 300 $\mu g/m^3$ ve yıllık 150 $\mu g/m^3$ iken 2014 yılına kadar düzenli olarak azaltılmıştır. 2014 ile 2019 yılları arasında da uygulanan tolerans miktarları sıfırlanmıştır ve sonucunda PM_{10} kirlilik limitleri Avrupa Birliğinin (AB) belirlemiş olduğu sınır değerler ile aynı olmuştur.

PM_{10} için belirlenen sınır değerler Türkiye'de AB standartlarındayken sağlık açısından daha tehlikeli olan $PM_{2.5}$ için limit değerler Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği'nde yer verilmemiştir. $PM_{2.5}$ kirliliğine ait hava kalitesinin izlenmesine yönelik Avrupa Birliği'nin 2008 yılındaki 2008/50EC no'lu Avrupa Parlamentosu ve Konseyi Direktifinde limit değerler belirlenmiştir. $PM_{2.5}$ için AB'nin belirlemiş olduğu limit değer yıllık 25 $\mu g/m^3$'tür (AB, 2008).

Türkiye ve Avrupa Birliğinde hava kirleticiler için belirlenen sınır değerler var olsa da Dünya Sağlık Örgütü'nün (DSÖ) belirlediği sınır değerler farklılık göstermektedir. Ozon için DSÖ'nün belirlemiş olduğu sınır değer 8 saatlik ortama için 100 $\mu g/m^3$'tür. Kükürt dioksit (SO_2) için DSÖ'nün belirlediği sınır değer ise 24 saatlik ortalamada 20 $\mu g/m^3$, 10 dakikalık ortalamada 500 $\mu g/m^3$'tür. DSÖ'nün PM_{10} ve $PM_{2.5}$ için belirlemiş olduğu sınır değerler Tablo 2.2'de belirtilmiştir (DSÖ, 2006).

Tablo 2.2: PM_{10} ve $PM_{2.5}$ sınır değerleri (DSÖ, 2006).

Kirletici	24 Saatlik Sınır Değer	Yıllık Sınır Değer
PM_{10}	50 $\mu g/m^3$	20 $\mu g/m^3$
$PM_{2.5}$	25 $\mu g/m^3$	10 $\mu g/m^3$

2.5. HAVA KALİTESİ İNDEKSİ

Hava kirliliği sorununu çözmek ve strateji geliştirmek adına ilgili otoriteler ve bilimsel çalışma üretenler hava kirleticilerini takip etmek ve analiz etmek için odaklanmışlardır. Hava kalitesinin korunması ve iyileştirilmesi otoritelerin sorumluluğu olsa da doğrudan halk sağlığına etkisi olduğundan hava kalitesi hakkında güncel bilgileri kamuoyuna sunması da bir sorumluluktur. Bunu yaparken, farklı kirleticilerin ölçüm sonuçlarını anlamak bu konuda uzman bilim insanları için mümkün olsa da halk ve yerel otoritelerin kolayca anlayabileceği şekilde sunulması gerekmektedir. Bu nedenle hava kirliliğinin halka sunumunu kolay anlaşılır bir şekilde yapılabilmesi adına hava kalitesi indeksi (HKİ) sınıflama sistemi kullanılmaktadır.

Tablo 2.3'de US EPA'nın, Tablo 2.4'de ise T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'nın belirlemiş olduğu hava kalitesi indeksi kesme noktaları yer almaktadır. Farklı kirleticiler için farklı konsantrasyon aralığı HKİ için bir sayıya denk gelmektedir. HKİ sayısı da hava kalitesinin iyi, orta, hassas, sağlıksız, kötü ve tehlikeli olmak üzere hangi sevide olduğunu ifade etmektedir.

Tablo 2.3: Hava kalitesi indeksi kesme noktaları (EPA, 2018).

İndeks		SO_2 (ppb)	NO_2 (ppb)	CO (ppm)	O_3 (ppm)		PM_{10} ($\mu g/m^3$)	$PM_{2.5}$ ($\mu g/m^3$)
		1 sa. ort.	1 sa. ort.	8 sa. ort.	8 sa. ort.	1 sa. ort.	24 sa. ort.	24 sa. ort.
İyi	0-50	0-35	0-53	0-4,4	0-0,054	-	0-54	0-12,0
Orta	51-100	36-75	54-100	4,5-9,4	0,055-0,070	-	55-154	12,1-35,4
Hassas	101-150	76-185	101-360	9,5-12,4	0,071-0,085	0,125-0,164	155-254	35,5-55,4
Sağlıksız	151-200	186-304	361-649	12,5-15,4	0,086-0,105	0,165-0,204	255-354	55,5-150,4
Kötü	201-300	305-604 (24 sa. ort.)	650-1249	15,5-30,4	0,106-0,200	0,205-0,404	355-424	150,5-250,4
Tehlikeli	301-500	605-1004 (24 sa. ort.)	1250-2049	30,5-50,4	-	0,405-0,604	425-604	250,5-500,4

Tablo 2.4: Ulusal hava kalitesi indeksi kesme noktaları (UHKİA, 2020).

İndeks		SO_2 ($\mu g/m^3$)	NO_2 ($\mu g/m^3$)	CO ($\mu g/m^3$)	O_3 ($\mu g/m^3$)	PM_{10} ($\mu g/m^3$)
		1 sa. ort.	1 sa. ort.	8 sa. ort.	8 sa. ort.	24 sa. ort.
İyi	0-50	0-100	0-100	0-5500	0-120	0-50
Orta	51-100	101-250	101-200	5501-10000	121-160	51-100
Hassas	101-150	251-500	201-500	10001-16000	161-180	101-260
Sağlıksız	151-200	501-850	501-1000	16001-24000	181-240	261-400
Kötü	201-300	851-1100	1001-2000	24001-32000	241-700	401-520
Tehlikeli	301-500	>1101	>2001	>32001	>701	>521

2.6. HAVA DURUMU, İKLİM ve METEOROLOJİK PARAMETRELER

Hava durumu atmosferdeki kısa süreli (dakikadan güne değişen) değişimlerden meydana gelmektedir. Hava, sıcaklık, nem, yağış, bulutluluk, görüş ve rüzgâr terimleriyle ifade edilir.

İklim ise atmosfer, hidrosfer ve kara yüzey sisteminin yavaş değişim gösteren görünümüdür. Tipik olarak sıcaklık (kara, okyanus ve atmosfer), tuzluluk (okyanuslar), toprak nemi (kara), rüzgâr hızı ve yönü (atmosfer), akım gücü ve yönü (okyanuslar) gibi değişkenler dahil olmak üzere atmosferin, okyanusun ve toprağın belirli durumlarının ortalamaları olarak karakterize edilir. Hava durumu ile iklim arasındaki fark; iklim beklenen, hava durumu ise elde ettiğiniz ortam şeklinde ifade edilebilir (NOAA, 2011; Lovejoy, 2013).

Hava durumu atmosferde meydana gelen meteorolojik olayları yani belirli bir orta enlem fırtınası veya bir kasırga gibi tek tek hava unsurlarının üretimi, yayılması ve tahmini ile ilgilenirken; iklim araştırması orta enlemdeki fırtınaların ve kasırgaların tamamıyla ilgilenir ve gelecek yıl pek çok fırtına ya da kasırga olacak mı ya da küresel ısınmanın bir sonucu olarak daha sık mı olacak yoksa yoğunlaşacaklar mı gibi sorulara cevap arar. "Hava durumu" terimi atmosferdeki kısa süreli meydana gelen meteorolojik olayları belirtirken, "iklim" terimi daha uzun zaman dilimlerini ele alır. Dünya Meteoroloji Örgütü, iklimi; istatistiksel özelliklerin belirlenmesine izin verecek kadar uzun bir süre boyunca hava istatistikleri olarak tanımlar. Hava durumu, belirli bir zamanda, belirli bir yerde atmosferin fiziksel durumunu tanımlarken, ortalamadan sapma olasılığını ve dolayısıyla aşırı hava olaylarının meydana gelme olasılığını içermedikçe, iklimin bir tanımı tamamlanmış sayılmaz. Genel olarak iklimin tanımlanması için referans dönem olarak otuz yıllık bir süre kullanılır (Latif, 2009).

Meteoroloji Genel Müdürlüğünün tanımına göre meteoroloji; "*Atmosferde meydana gelen hava olaylarının oluşumunu, gelişimini ve değişimini nedenleri ile inceleyen ve bu hava olaylarının canlılar ve dünya açısından doğuracağı sonuçları araştıran bir bilim dalıdır."*. (MGM, 2021a) Sıcaklık, basınç, nem, yağış, rüzgâr hızı ve yönü, güneşlenme, bulutluluk, buharlaşma vb. birer meteorolojik parametredir.

Günlük ortalama hava kirliliği konsantrasyonlarının zamansal değişimi, çoğunlukla kirliliğin dağılımını etkileyen hava koşulları ile ilişkiliyken kirletici kaynakların gücündeki değişikliklerle ilişkisi daha azdır. Önemli faktörler arasında rüzgâr yönü, rüzgâr hızı ve atmosferik stabilite yer alır (Newby ve diğ., 2015).

2.6.1. Sıcaklık

Meteorolojik bir parametre olarak sıcaklık, havanın ne kadar sıcak olduğu veya ne kadar termal enerji içerdiğinin bir ölçüsüdür. Sıcaklık bir kinetik enerjidir ve termometre ile ölçülür. Sıcaklık hava biliminde, özellikle de çoğu kirlilik çalışmasında temel bir ölçüdür. Örneğin, bir baca gazı

bulutunun sıcaklığı, onun kaldırma gücünü ve çevre sıcaklığına ulaşmadan önce atık gaz bulutunun ne kadar yükseleceğini belirler. Bu da kirletici izleri zemin seviyesine ulaşmadan önce ne kadar seyreltileceğini belirler. Sıcaklık farklı ölçeklerde ölçülebilir; örneğin suyun donma noktası Celsius birimi olarak 0°C şeklinde ifade edilirken Fahrenheit birimi olarak 32°F şeklinde ifade edilir. Enerji azaldıkça moleküllerin hareketi azalır ve sonunda belirli bir enerji seviyesinde durur. Bu seviye mutlak sıfır olarak isimlendirilir, mutlak sıcaklık ölçümü Kelvin (K) ile ifade edilir ve Kelvin cinsinden mutlak sıfır sıcaklığı 0 K'dır. Celsius cinsinden bu sıcaklık -273°C olarak ifade edilir (Spellman, 2012).

İklim için en önemli parametreler sıcaklık, basınç ve yağıştır. Yağışın yer yüzüne düşme formu ve basınç üzerinde büyük etkisi vardır. Güneş ışınlarının taşımış olduğu enerjinin büyük bir bölümü atmosferden geçerek ısı enerjisi olarak yer yüzeyine ulaşır ve ısınmasını sağlar. Bu nedenle güneş radrasyonu havanın ısınmasında ve soğumasında etkin bir faktördür. Güneşin hava sıcaklığını etkisini bir faktör olarak ele alırsak hava sıcaklığını etkileyen diğer faktörler; yer yüzeyinin yapısından kaynaklı faktörler, zemin şekli ve güneşlenme açısı ve atmosferik etkiler olarak sıralanabilir (Yalçın ve diğ., 2005).

2.6.2. Basınç

Atmosfer basıncı, atmosferin bir yüzeye uyguladığı kuvvet miktarıdır. Bir başka deyişle hava basıncı vücudumuzun çevremizi saran havanın ağırlığı olarak tanımlanmaktadır (Spellman, 2012).

Barometre ile ölçülen atmosfer basıncı normal şartlar altında 760 mm, yaklaşık olarak 1013 mb olarak kabul edilmektedir. Buna göre 1013 mb üzerindeki basınç değerine yüksek basınç, 1013 mb altındaki basınç değerine alçak basınç denilmektedir. Yükseklik, sıcaklık, hava yoğunluğu, yerçekimi ve enlemler basıncın değişmesi üzerine etkilidir (Yalçın ve diğ., 2005).

Yer yüzündeki basınç farklılıkları havanın hareketlenmesine neden olur, yüksek basınçtan alçak basınca doğru olan akımdan dolayı yatayda oluşan harekete rüzgâr, atmosfer içinde dikeyde olan hareketlere konveksiyon ve çökme adı verilir. Dikey hareketler en önemli hareketlerdir çünkü bulutları ve yağışları oluşturur ya da dağıtır. Yüksek ve alçak basınç merkezleri hava haritaları üzerinde kilit role sahiptir, rüzgâr yönü ve hızı, bulutluluk ve yağış hakkında bilgi sağlar (Whiteman, 2000).

2.6.3. Yağış

Kara ve denizler ile bunların üzerinde yaşayan insanları, hayvanları ve bitki örtüsünü etkileyen hava sistemlerinin getirdiği başlıca eylemler rüzgâr ve yağışlardır. İnsanları etkileyen hava olaylarının en önemlisi fırtınalar şeklinde meydana gelir. Fırtınalar bölgesel olabilir ancak daha yaygın bir şekilde izledikleri yol boyunca geniş alanlara taşınır ve bu durumu yüksek ve alçakta oluşan aktif hava kütleleri takip eder. Fırtınalardaki ana bileşen, sıvı veya buhar formunda olan sudur. Buhar, bir gaz gibi davranır ve böylece atmosferin toplam basıncına katkıda bulunur ve atmosferin küçük ama hayati bir bölümünü oluşturur.

Havadaki su buharının miktarı kaynaklara, süreçlere ve hava sıcaklığına bağlı olarak değişir. Isı enerjisi esas olarak güneş ışıması şeklinde temin edilir ancak bir kısmı dünya ve insan faaliyetlerinden ve bir kısmı da hal değişimi süreçlerinden kaynaklı oluşur. Bu enerji termal olarak su kütlelerinden (okyanuslar, göller, nehirler), bitkilerden, topraktan su moleküllerinin enerjisini arttırarak hareketlenmesine ve bu kaynaklardan uzaklaşmasına neden olur. Bu olaya buharlaşma denir. Atmosferdeki buharlaşmış su buharına nem adı verilir, meteorolojik olarak kullanılan nem bağıl nemi ifade eder. Bağıl nem doyma noktasına yükseldiğinde hava sıcaklığının da etkisiyle yağış formuna dönüşür.

Yağışlar çeşitli şekillerde bulunur. Hangi formda zemine ulaştığı birçok faktöre bağlıdır. Bu faktörler; atmosferik nem içeriği, yüzey sıcaklığı, yukarı doğru akımların yoğunluğu, soğutma yöntemi ve hızıdır (Spellman, 2012). Yağış miktarı 1 m^2'lik alana düşen mm cinsinden yağış miktarı ile ifade edilir.

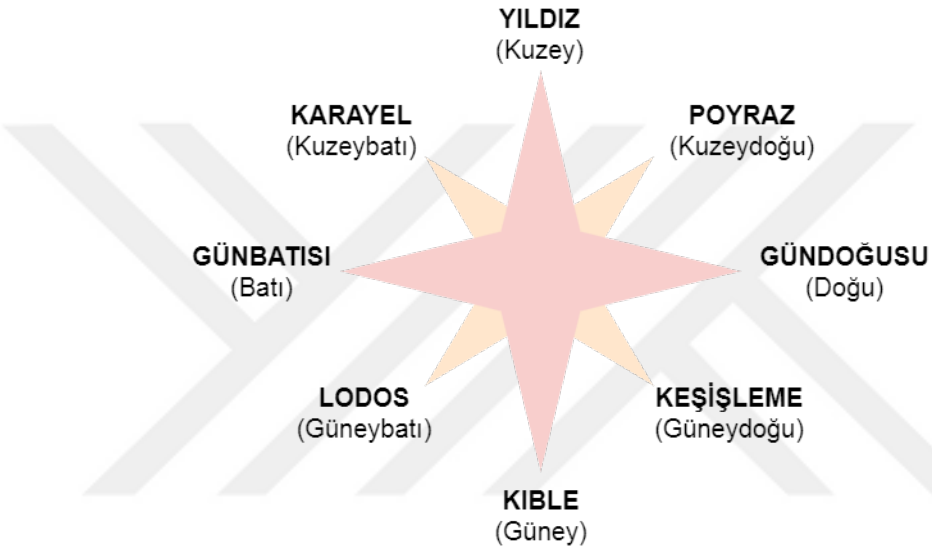
2.6.4. Rüzgâr

Belli bir bölgede hava ısınır ve basıncı arttığında veya soğuyup basıncı düştüğünde o bölgenin çevresi ile arasında basınç farklılığı söz konusu olur. Basınç farklılığından kaynaklı hava yoğunluğunda da farklılık olmaktadır. Yeryüzünde oluşan yoğunluk farkının giderilerek yoğunluğun eşitlenmesi için yüksek basınçlı havaya sahip bölgeden alçak basınca sahip bölgeye doğru yatay yönde hava akışı oluşur. Bu hava akışına rüzgâr adı verilir (Yalçın ve diğ., 2005).

Rüzgâr, meteorologları ilgilendiren iki ölçümü olan bir hava unsurudur. Bu ölçümler rüzgâr yönü ve rüzgâr hızıdır. Rüzgâr yönü, kendisini karşıdan gelen bir rüzgâra dönüştürmek için tasarlanan rüzgâr gülü ile ölçülür, rüzgârın geldiği yönü belirtir. Rüzgâr hızı temel bir atmosferik hızdır ve bir anemometre ile ölçülür. Ayrıca rüzgâr hızı insanların özel olarak

tanımlanmış rüzgâr etkilerine ilişkin gözlemlerine dayanan eski Beaufort ölçeği kullanılarak da sınıflandırılabilir (Spellman, 2012).

Rüzgâr yönü, rüzgârın o bölgeye doğru estiği yöndür. Rüzgâr yönleri Kuzey, Doğu, Batı, Güney olmak üzere ana yönlerle ve Kuzeydoğu, Güneybatı vb. şekillerde ara yönlerle ifade edilir. Ülkemizde rüzgâr yönlerinin yerel ve bölgesel isimleri vardır (Şekil 2.2). Örneğin kuzeyden esen rüzgarlara Yıldız, güneydoğudan esen rüzgarlara Keşişleme veya Samyeli, kuzeydoğudan esen rüzgarlara Poyraz, güneybatıdan esen rüzgarlara Lodos adı verilmektedir.

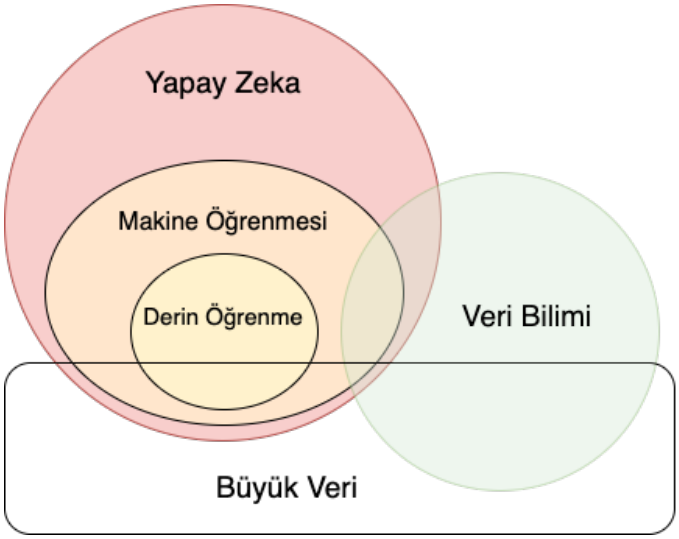


Şekil 2.2: Rüzgâr yönleri.

Rüzgâr yönünün gündelik hava şartlarının oluşumu ve iklimler üzerinde önemli etkisi vardır. Rüzgarlar bir hava kütlesi hareketi olduğundan geldikleri bölgeden nem, kuru hava, sıcaklık veya soğukluk taşıyabilirler. Rüzgarlar denizciler için de ayrı öneme sahiptir. Karadan denize doğru olan rüzgarların aksine açık denizden karaya doğru esen rüzgarlar yüksek dalgalar oluşumuna neden olmaktadır (Yalçın ve diğ., 2005).

2.7. EĞİTİLEBİLİR ALGORİTMALAR

Bilgisayar yazılımları ile zekanın taklit edilmesine yapay zekâ denilmektedir. Teknolojinin gelişimi ile son yıllarda yapay zekânın alt dalları olan Makine Öğrenmesi, Yapay Sinir Ağları, Genetik Algoritma, Uzman Sistemler ve Bulanık Mantık araştırma ve uygulamalarda kullanımı yaygınlaşmıştır (Tungut, 2019). Yapay zekânın alt dalları ve diğer veri bilimleri ile etkileşim diyagramı Şekil 2.3'de sunulmuştur.



Şekil 2.3: Yapay zekâ ve veri bilimi diyagramı.

2.7.1. Makine Öğrenmesi

Makine öğrenmesi yapay zekânın bir alt dalı olarak oluşmuştur. Yapay zekâ çalışmaları 1950'li yıllarda başlamıştır ve ardından makine öğrenmesi 1980'li yıllarda gelişmiştir. Makine öğrenmesi yapay zekâ ve veri biliminin ardında yer alan teknolojinin temeli olarak görülmektedir, veriye ve hesaplamaya endekslidir. Makine öğrenmesi örnek verileri veya geçmiş deneyimleri kullanarak bir performans kriterini optimize etmek için oluşturulan bilgisayarlar programlamasıdır. Bazı parametrelere göre tanımlanmış bir modele göre, öğrenme verilerini veya geçmiş deneyimleri kullanarak modelin parametrelerini optimize etmek için bir bilgisayar programının işlemesidir. Model, geleceğe yönelik tahminler yapmak için öngörücü veya verilerden bilgi edinmek için tanımlayıcı veya her ikisini de yapabilmektedir. Bir insan tarafından tasarlanıp gerçekleştirilemeyecek kadar karmaşık işlemleri makine öğrenmesi ile yapabilmekteyiz. Her farklı fonksiyon o fonksiyonun nasıl ilerleyeceğini belirleyen parametrelere sahiptir. Fonksiyondaki parametreleri, verileri verimli bir şekilde temsil etmek üzere değiştirmeye ise eğitim (öğrenme) denir (Alpaydın ve Bach, 2014; Gürsakal, 2018; Kalıpsız ve Cihan, 2016).

Makine öğrenmesi, matematiksel modeller oluştururken istatistik teorisini kullanır, çünkü temel prensibi bir örnekten çıkarım yapmaktır. Bilgisayar biliminin rolü iki yönlüdür: birincisi eğitim, optimizasyon problemini çözmek için ve ayrıca genel olarak sahip olduğumuz büyük miktarda veriyi işlemek için verimli algoritmalar oluşturmak; ikincisi ise bir model bir kez öğrenildiğinde verimli algoritmik çözüm ile çıkarımların oluşturulmasıdır. Bazı uygulamalarda öğrenme veya

çıkarım algoritmasının etkinliği, yani uzay ve zaman karmaşıklığı, tahmin doğruluğu kadar önemli olabilmektedir (Alpaydın ve Bach, 2014).

Makine öğrenmesi bilgisayarları, kendilerine sunulan girdilerden öğrenebilecekleri şekilde programlamaktır, kısacası tecrübeyi bilgiye dönüştürme sürecidir. Bir öğrenme algoritmasının girdisi, deneyimi temsil eden eğitim verileridir ve çıktısı genellikle bazı görevleri gerçekleştirebilen başka bir bilgisayar programı şeklini alan bir uzmanlıktır (Shalev-Shwartz ve Ben-David, 2014).

Makine öğrenmesi yalnızca bir veritabanı çözümleyicisi değil aynı zamanda yapay zekanın bir parçasıdır. Değişen bir ortamda bulunan bir sistemin zeki olabilmesi için öğrenme yeteneğine sahip olması gerekir. Sistem bu tür değişiklikleri öğrenebilir ve bunlara uyum sağlayabilirse, sistem tasarımcısının olası tüm durumlar için öngörüde bulunmasına ve çözüm sağlamasına gerek yoktur (Alpaydın ve Bach, 2014).

Makine öğrenmesi teknikleri perakende sektörü, finans sektörü ve bankalarda dolandırıcılık tespitinde, borsada kullanılacak modeller oluşturmak için geçmiş verilerini analiz etmede, imalat sektöründe optimizasyon, kontrol ve sorun gidermek için ve tıpta tıbbi teşhis koymak için öğrenme modelleri kullanılır. Telekomünikasyonda, ağ optimizasyonu ve hizmet kalitesini en üst düzeye çıkarmak için çağrı kalıpları makine öğrenme ile analiz edilir. Bilimde fizik, astronomi ve biyolojideki büyük miktarda veri ancak bilgisayarlar tarafından yeterince hızlı analiz edilebilir (Alpaydın ve Bach, 2014).

2.7.2. Bulanık Mantık

Bulanık mantık ilk olarak 1965 yılında Bulanık Kümeler teorisini geliştirirken Prof. Dr. Lotfi Zadeh tarafından dünyaya tanıtılmıştır. Dr. Zadeh'in çalışmaları bilgisayarların doğal dili anlama problemleri üzerinedir (Zohuri ve Moghaddam, 2017).

Bulanık mantık, bir uzmanın pratik deneyimine güvenebilen, özellikle deneyimli uzman bilgisini yakalamak için yararlı olan kural tabanlı bir sistemdir. Örneğin bulanık mantık için bir hava sıcaklığı tanımı yapılırken sadece sıcak veya soğuk sonucu yoktur, bunların yanı sıra ılık, çok sıcak ve çok soğuk gibi ara değerlere de varılabilmektedir.

Bulanık mantık kavramı dilsel terimleri kullandığı için insan düşünce tarzına yakındır. Değişkenlere, üyelik derecelerine izin verir. Her bir girdinin bulanık kümelerinin farklı durumları bulanık sistemin If-Then (Eğer-İse) kurallarına göre değerlendirilir. Bu işlem

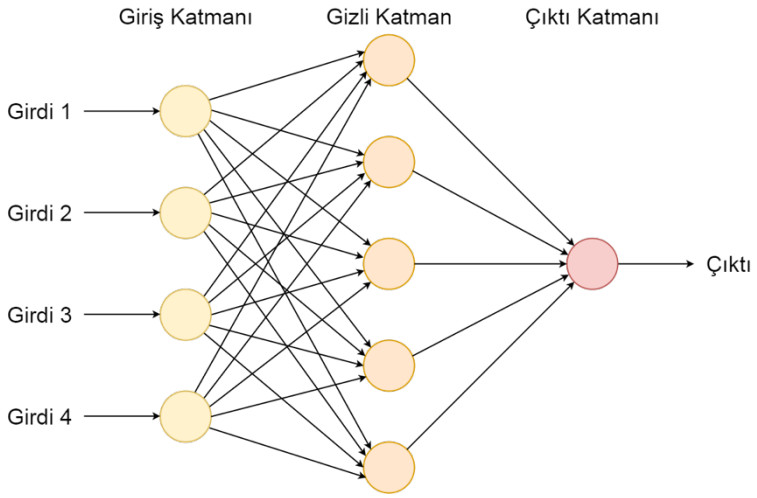
sonucunda hedef çıktılara çok yakın optimum çıktılar elde edilir. Sistem için optimum sonuçların oluşturulması uzmanın deneyimine bağlıdır (Yavuz ve diğ., 2001).

Sistem kontrolü ve analiz tasarımında başarılı bir şekilde uygulanan bulanık mantık mühendislik uygulamalarında geliştirme süresini kısaltır ve bazen oldukça karmaşık sistemlerin çözümünde en etkili yol olmaktadır. Ayrıca ekonomi, psikoloji, pazarlama, hava tahmini, biyoloji, politika vb. büyük karmaşık sistemlerin çözümünde kullanılabilmektedir (Zohuri ve Moghaddam, 2017).

2.7.3. Yapay Sinir Ağları

Yapay sinir ağları (YSA) akıllı, insan benzeri bir bilgi uygulamasıyla daha karmaşık veri analizi özelliklerini mevcut uygulamalara uygulayan bir tür yapay zekâ teknolojisidir. YSA, biyolojik (beyin) sinir ağlarına dayalı matematiksel model veya bir bilgisayar modeli olarak düşünülebilir. Birbirine bağlı yapay nöron gruplarından oluşur ve bağlantıları ve hesaplamaları kullanarak bilgiyi işler. Aynı zamanda YSA, öğrenme aşaması sırasında ağ içinde işlenen dış veya iç bilgilere dayalı olarak yapısını değiştiren ve bir tür doğrusal olmayan istatistiksel bir türe çok benzeyen uyarlanabilir bir modelleme aracıdır. Bu sinir ağları, girdiler ve çıktılar arasındaki karmaşık ilişkileri modellemek veya analiz edilen veri kümelerinde var olan veya yeni modelleri ortaya çıkarmak için kullanılabilir (Kwon, 2011).

Bir YSA'nın amacı, ağın yeni tanıtılan girdilerden çıktıları genelleştirmesini ve tahmin etmesini sağlamak için bir veri üreten süreç modeli oluşturmaktır. Bu öğrenme algoritması çok katmanlı bir sinir ağını içerir ve bir girdi katmanı, gizli katmanlar ve bir çıktı katmanı içerir. Gizli ve çıktı katmanındaki nöronlar her girdiyi karşılık gelen bir ağırlıkla çarpar, çarpımı toplayıp toplamı doğrusal olmayan bir transfer fonksiyonu kullanarak işler. Katmanların akış süreci Şekil 2.4’de görülmektedir (Öngen ve diğ., 2013)



Şekil 2.4: Yapay sinir ağı diyagramı.

Verileri birbirine bağlı ve nedensel ilişkiler dizisi olarak görselleştirmek için yapay zekâ, verileri düzenlemek ve görüntülemek için genellikle bir yapay sinir ağı kullanır. YSA, karmaşık kurumsal verileri anlamlandırmak için birden fazla nedensellik ve bağlantı tanımını barındırır (Moye, 2019).

Teknolojideki ilerleme nedeniyle, yapay zekâ tabanlı algoritmalar, özellikle hava kalitesi tahmini için tahmin amacıyla yaygın olarak kullanılmaktadır. Bir makine öğrenimi yaklaşımı, saf bir istatistiksel modelden farklı olarak tahmin için birden çok parametreyi hesaba katar. Yapay sinir ağları, hava kalitesinin tahmini için en yaygın kullanılan teknik olarak ortaya çıkmıştır (Srivastava ve diğ., 2018). Ayrıca yapay sinir ağları tabanlı yöntemler, büyük ölçüde yerel meteorolojik koşullara ve kirletici konsantrasyonlarına dayanan hava kalitesi izlemede yaygın olarak kullanılmaktadır (Djebbrii ve Rouainia, 2018).

2.7.4. Genetik Algoritma

Genetik algoritma (GA) yaşamdaki evrimsel gelişim mekanizmasını temel alan yapay zekâ yöntemidir. Adından da anlaşıldığı üzere, Darwin'in evrim teorisinden yapılan çıkarımla yaratılmıştır. Evrende geçerli olan en iyinin yaşaması kuralına göre daima gelişen çözümler geliştirir. GA, parametre kodlama temeline dayalı çözüm ararken rastlantısal arama tekliklerinden faydalanan sezgisel arama yöntemidir (Göktaş ve Yeniay, 2003; Gülsün ve diğ., 2009).

Geleneksel uygulamalarla çözümü zor ve zahmetli olan sorunların çözümünde güçlü algoritma yapısı ile başarılı bir şekilde uygulanabilmesi ile kendini ispatlamıştır. İlk olarak John Holland tarafından 1970'li yıllarda (Holland, 1992) çıkan GA'lar endüstriyel uygulamalarda, deneysel

çalışmalarda optimizasyon, sınıflandırma ve birçok farklı mühendislik uygulamalarında sıklıkla kullanılmıştır (Aleixandre ve diğ., 2004; Öztürk ve diğ., 2005; Gülsün ve diğ., 2009).

Genetik algoritma, en iyileme problemlerini bilgisayar ortamında soyut temsiller olarak tanımlanan kromozomlar kullanır. Bilgisayar sistemlerinde çözümlemeler 0 ve 1'lerin oluşturduğu zincirlerden meydana gelir. Evrim denen olgu bir bireyle başlayıp nesillerde görülen iyi yönlü değişimdir. Yeni popülasyonun oluşumunda var olan popülasyon içinden her nesilde farklı bireyler seçilir, mutasyona uğrama veya yeniden kopyalama ile değişikliğe uğrayan yeni popülasyon, algoritma içindeki bir sonraki tekrarda görev alır. Genetik algoritmaların yapısı basit ve oldukça anlaşılabilir ve bu nedenle problemlere uygulanabilirliği kolaydır. Bir amaç fonksiyonun yaratılması, problemdeki değişkenlerin kodlanması neyin iyi olduğunu GA'ya bildirilir ve sonucunda karmaşık olarak tanımlanan çeşitli problemler genetik algoritma yardımı ile çözülebilmektedir (Yüksel ve diğ., 2016).

2.7.5. Uzman Sistemler

Uzman sistemler; *"İnsanlar tarafından çözümü zor olan problemlerin çözümünde kendisine ait bir bilgi tabanı ve bu bilgi tabanından gerekli bilgileri çıkaran bir çıkarsama mekanizması (inference mechanism) ile istenen sonuca ulaşmayı sağlayan bir yapay zekâ tekniğidir."* (Cebesoy, 1995)

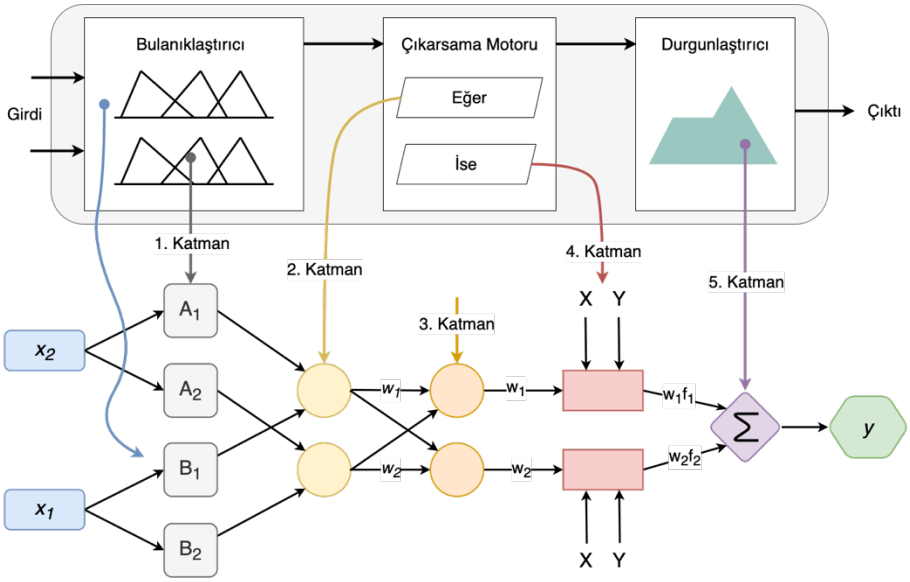
Daha basit bir şekilde açıklanacak olursa bir uzman sistem, uzman olan insanın karar verme becerisini taklit eden bilgiye dayalı bir yapay zekâ uygulamasıdır. Uzman sistem uygulamaları uzmanların çıkar yol arama ve bilgi kabiliyetine varma ve bu kabiliyetten yararlanma imkânı veren yazılımlardır. Algoritmalardan oluşan yazılıma insan zekasının uzman becerileri aktarılmaktadır ve bu beceri sıklıkla karmaşık problemleri çözmek için kullanılmaktadır. 1970'li yıllarda başlayan uzman sistem çalışmaları ilerleyen yıllarda mühendislik, yönetim, sanayi ve ar-ge çalışmalarında ağırlıklı olarak kullanılmıştır. Genel olarak uzman sistemlerde iki farklı alt sistem yer almaktadır. Birincisi uzman bilgi tabanıdır; kurallar ve doğru bilgilerin yer aldığı bir bilgi deposudur. İkincisi olan çıkarsama motoru; uzman bilgi tabanındaki kural ve doğru bilgileri kullanarak yeni tavsiye ve değerlendirme sonucu üretir (Başoğlu ve Bulut, 2017).

2.8. EĞİTİLEBİLİR ALGORİTMA MODELLERİ

Tez çalışmasının bu aşamasında sahada elde edilen veri setine uygun olacak şekilde çeşitli makine öğrenmesi metotları uygulanmış, elde edilen bulgular 4. bölümde açıklanmıştır.

2.8.1. Adaptif Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neuro Fuzzy Inference System, ANFIS)

Sinir ağları ve bulanık sistemlerin bir kombinasyonu olan ANFIS'in temeli Takagi-Sugeno Kang bulanık çıkarım sistemidir. 1993 yılında Jang tarafından geliştirilen (1993) ANFIS yöntemi doğrusal olmayan yapıları modellemek, sistemleri kontrol etmek, doğrusal olmayan bileşenleri tespit etmek ve kaotik zaman serilerini tahmin etmek için kullanılmıştır. ANFIS'in yapısında hem yapay sinir ağları hem de bulanık mantık kullanılır. Sinir ağı ile bulanık sistemin kombinasyonu bulanık sinir ağı olarak adlandırılır. ANFIS, öğrenme ve adaptasyon işlemlerini kolaylaştırmak için, adaptif sistemlerden yararlanan bulanık Sugeno modelidir (Gill ve diğ., 2020). Böyle bir yaklaşım bulanık mantığı daha sistematik ve tecrübeye daha az bağlı hale getirmektedir. ANFIS'in temel amacı, eşdeğer bulanık mantık sisteminin parametrelerini, giriş-çıkış veri kümelerini kullanarak bir öğrenme algoritması vasıtasıyla optimize etmektir. Parametre optimizasyonu, gerçek çıkış ile hedef çıkış arasındaki hata değeri minimum olacak şekilde yapılmaktadır. Birinci derece bulanık Sugeno modeli için olası ANFIS mimarisi Şekil 2.5'de verilmiştir.



Şekil 2.5: ANFIS mimarisi.

ANFIS modelinin katmanlarını genel olarak özetlersek, 1. katmanda giriş verilerine üyelik fonksiyonları uygulanarak bulanıklaştırma işlemi yapılır. 2. katmanda bulanık mantık çıkarım sistemine göre Eğer-İse (If-Then) kurallar oluşturulur.

Kural 1: Eğer $x=A_1$ ve $y=B_1$ ise $f_1 = p_1x + q_1y + r_1$

Kural 2: Eğer $x=A_2$ ve $y=B_2$ ise $f_2 = p_2x + q_2y + r_2$

3. katmanda kural katmanından gelen her bir düğüme, ağırlıklı ortalama ile normalizasyon işlemi uygulanır. 4. katmanda ise bulanık sonuçlar sayısal değerlere dönüştürülür ve son olarak 5. katmanda tüm düğümlerin çıkış değerleri toplanarak sistemin tek çıkış değeri üretilir (Yavuz ve diğ., 2001).

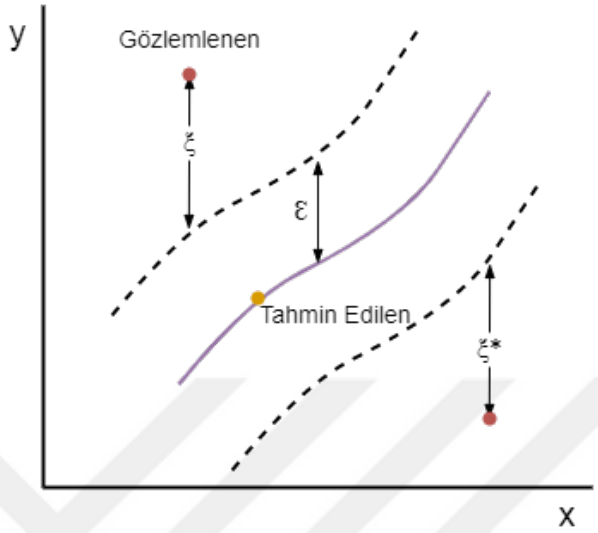
Çalışılan uygulamalarda tahmin için sinir ağlarına dayalı hibrit modellerin veya karma modellerin kullanımı görülmektedir. Bulanık mantık, genetik algoritma ve yapay sinir ağlarına dayalı temel bileşen analizi (Principal component analysis, PCA) gibi yapay zekâ algoritmaları ANFIS modeli, PCA-ANN modeli vb. modellerin tasarımında kullanılmaktadır (Srivastava ve diğ., 2018).

2.8.2. Destek Vektör Regresyonu (Support Vector Regression, SVR)

Destek vektör regresyonu (SVR), regresyon için eldeki verileri analiz etmek üzere oluşturulmuş öğrenme algoritması ile ilişkili bir makine öğrenimi regresyonudur. Regresyon ve sınıflandırma işlemleri için uygulanan bir öğrenme yöntemi olan destek vektör makinalarının (SVM) bir parçasıdır. SVM Vapnik tarafından geliştirilmiştir, geleneksel öğrenme yöntemlerine göre doğrusal olmayan problemleri çözme becerisi çok daha yüksektir (Vapnik, 1999). SVM daha çok sınıflandırma modellerinde kullanılırken regresyon için geliştirilmesi Smola ve arkadaşları tarafından olmuştur ve SVR adını almıştır (Smola ve Schölkopf, 2004).

Temel fikir, örnek noktaları doğrusal olmayan bir haritalama yoluyla yüksek boyutlu özellik uzayına eşlemek ve yüksek boyutlu özellik uzayında doğrusal regresyon gerçekleştirmek, ardından orijinal alanda doğrusal olmayan regresyon tahmini elde etmektir**.** SVR eğitim aşamasında öğrenilen giriş-çıkış ilişkisini kullanarak, daha önce öğrenilmemiş test verileri için iyi genelleme performansı sergilemektedir. Sürekli değerli bir fonksiyona yaklaşım problemi için $x_S \in R^n$ girdi vektörünü, $y_S \in R$ çıktı (hedef) değerini belirtecek şekilde N sayıda örnekten oluşan bir veri seti $D=\{(x_S, y_S) \mid s \in \{1,2,...,N\}\}$verilmiş olsun. Regresyon analizinin amacı

istenen (hedef) çıktıları ($y_S \in R$) doğru bir şekilde tahmin edebilmek için matematiksel bir fonksiyon belirlemektir (Karal ve Büyükberber, 2018). Örnek destek vektör regresyonu diyagramı Şekil 2.6'da verilmiştir.

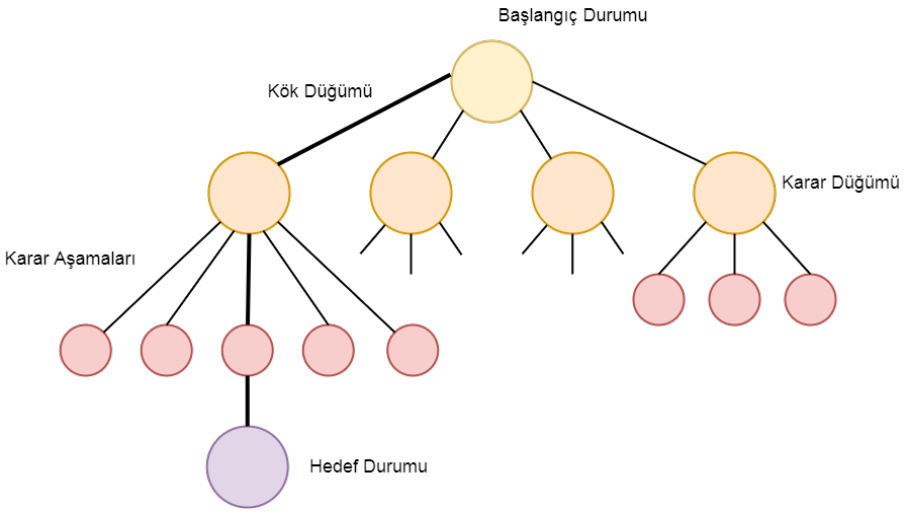


Şekil 2.6: Destek vektör regresyonu diyagramı (Drucker ve diğ., 1996).

2.8.3. Kümeleme ve Regresyon Ağaçları (Classification and Regression Trees, CART)

Kümeleme ve regresyon ağaçları (CART), 1984 yılından Breiman ve Stone tarafından geliştirilen, verileri sınıflandırma ve tahmin etme işlemlerinde kullanılan bir karar ağacı modelidir. Karar ağacı bir dizi soruya mantıklı birer yanıt yolu gösteren akış şemasından oluşmaktadır. Eldeki veriler mantıksal olarak veya ağaç yapısı ile son hedefe doğru giderken eldeki veriler hakkında nitel bir ifade ve nicel bir tahmin yapılabilir (Ma, 2018).

Temel amaç bağımlı değişkene göre bağımsız değişkenleri homojen alt gruplara ayırmaktır. Eğer bağımlı değişken kategorik ise yöntemin adı sınıflandırma ağacı (CT), sürekli ise regresyon ağacı (RT) ismini alır. Alt grupların oluşturulmasında veri dallanan bir ağaç şeklinde hiyerarşik bir düzende sunulur. Ağaç yapısı ve kolay kural çıkarımı sayesinde araştırmacılar tarafından sıklıkla kullanılan bir yöntemdir (Breiman ve diğ., 2017). Kümeleme ve regresyon ağaçları genel yapısı Şekil 2.7'de sunulmuştur.

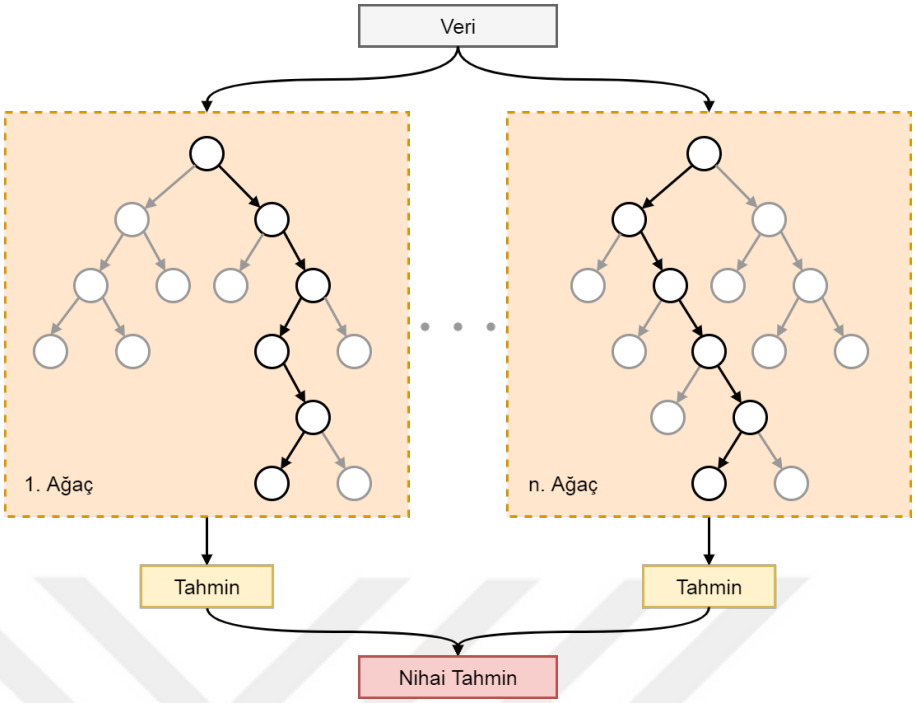


Şekil 2.7: Kümeleme ve regresyon ağaçları genel yapısı.

2.8.4. Rastgele Orman (Random Forest, RF)

Rastgele orman (RF) topluluk tabanlı, denetimli bir makine öğrenmesi algoritmasıdır. Sınıflandırma ve regresyon problemleri için kullanılan atomik bir birim olarak çok sayıda rastgele karar ağaçlarından oluşur. RF paralel iş parçacıkları olarak uygulanabilir ve yürütülebilir, bu nedenle uygulanması hızlı ve kolaydır. Tıbbi görüntüleme, örüntü tanıma, sınıflandırma ve regresyon gibi çeşitli alanlarda kullanılmaktadır.

Topluluk öğrenme yöntemlerinden birisi olan rastgele orman, karar ormanındaki her bir ağacı veri seti içerisinden bootstrap tekniği ile rastgele örnekler seçerek oluşturur. Bagging yönteminden farklı olarak örnek seçimi ile birlikte değişkenlerin seçimi içinde rastgelelik söz konusudur. Her düğüm noktasında bütün değişkenler arasından belirlenen bir sayıda rastgele şekilde değişken seçilerek en iyi bölünme sağlayacak olan değişken belirlenip dallara ayırma işlemi belirlenen bu değişken ile başlar. Değişken seçiminde kullanılan random subspace yöntemi, veri setindeki tüm değişkenler içerisinden rastgele seçilen az sayıdaki değişken içerisinden değişken seçilmesi şeklinde uygulanır. Amaç ağacın her bir düğümünde en iyi dal bölümlenmesini sağlayacak değişkenlere ulaşmaktır (Liaw ve Wiener, 2002). Daha doğru ve istikrarlı sonuçlar elde etmek için RF modeli çoğunluk oylama sürecini kullanır. Regresyon problemlerinde tüm ağaçların ortalaması alınarak gözlem için tek bir tahmin elde edilir. Sınıflandırma problemlerinde, her ağacın sınıflandırması, çoğunluk oyu mekanizması aracılığıyla nihai bir sınıflandırmada birleştirilir. Şekil 2.8'de rastgele orman yöntemi genel yapısı görselleştirilmiştir.

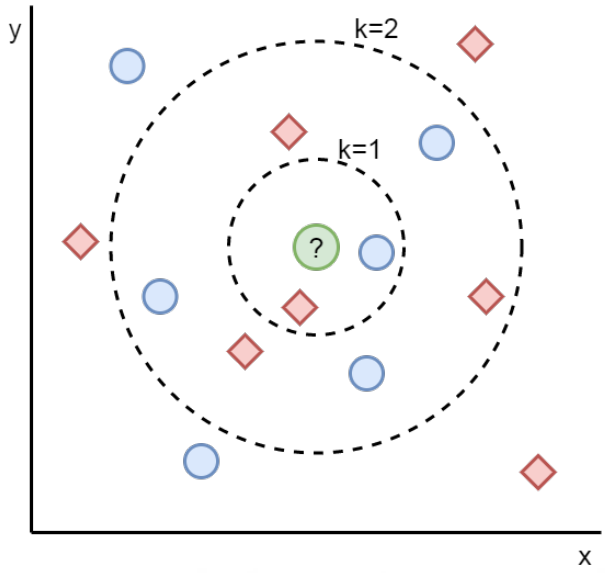


Şekil 2.8: Rastgele orman yöntemi genel yapısı.

2.8.5. K-En Yakın Komşu Algoritması (K-Nearest Neighbor, KNN)

K-en yakın komşu algoritması ilk olarak 1967 yılında Cover ve Hart tarafından önerilmiştir. Sınıflandırılmamış örnekler kurallara göre en yeni sınıflandırma kategorisine atanır. Bu algoritma bir tür denetimli öğrenme algoritmasıdır ve veri dağılımı için düşük gereksinim, güçlü uyarlanabilirlik ve yüksek hassasiyet avantajlarına sahiptir. Bununla birlikte veri setlerinin işlenmesindeki yavaşlık dezavantaj oluşturmaktadır (Li, Ji ve Li, 2018).

K-en yakın komşu algoritması, makine öğrenmesi algoritmalarının en basit yöntemlerinden biri ve sınıflandırma yöntemidir. Bu algoritma sınıflandırma işlemi için gözlemler arası uzaklık hesabına dayanır. Sınıfı bilinmeyen gözlemin var olan gözlemlere uzaklıklarının hesaplanması ve en az uzaklığa sahip k tane gözlemin seçilmesi işlemi ile gerçekleştirilir (Şekil 2.9). Genelde uzaklık hesabı için Öklid uzaklık formülü kullanılır. Test edilen veriyi tüm eğitim kümesiyle karşılaştırdığından oldukça uzun zaman harcamaktadır (Altman, 1992).



Şekil 2.9: K-en yakın komşu yöntemi genel yapısı.

2.8.6. Aşırı Öğrenme Makinesi (Extreme Learning Machine, ELM)

Aşırı öğrenme makinesi (ELM), Huang ve arkadaşları tarafından geliştirilen tek gizli katmanlı ileri beslemeli yapay sinir ağları yöntemini temel alır. Yöntem, girdi ağırlıklarını ve gizli katman düğüm eşiklerini rastgele üretebilir ve yinelemeli işlemlere gerek kalmadan çıktı katmanı ağırlıklarını hesaplayabilir, bu nedenle hesaplama hızı geleneksel yapay sinir ağı algoritmasından çok daha iyi sonuç vermektedir (Khurana ve Saxena, 2021). Son yıllarda geleneksel sinir ağlarının kusurlarını etkin bir şekilde iyileştirme yeteneğine sahip olan ELM yüz tanıma, sınıflandırma, regresyon, görüntü işleme, zemin yeniden oluşturma ve benzeri gibi çeşitli disiplinlerin çeşitli alanlarında uygulanmaktadır.

ELM hızlı öğrenme yeteneğine ve iyi bir genelleme performansına sahip olmasına rağmen, gizli katman tasarım dizisindeki bazı sütun vektörleri doğrusal korelasyona yaklaştığında gizli katman tasarım dizisi çoklu lineerliğe sahip veya hatalı konumlanmıştır. Kötü koşullandırılmış matrisin çözümünü tahmin etmek için sıradan en küçük kareler yöntemini kullanarak zayıf genelleme performansı ve kararlılığı ile sonuçlanabilir (Li, Cai ve Liu, 2018).

2.9. R PROGRAMLAMA

Verilerin ve veri biliminin giderek daha önemli hale geldiği dünyada farklı iş sektörleri ve araştırmacılar büyük veri setlerini verimli bir şekilde analiz etmek ve işlemek için bilgisayar destekli araçlara ihtiyaç duymaktadır. Bu amaçla 1991 yılında Auckland Üniversitesi İstatistik Bölümünde görev alan Ross Ihaka ve Robert Gentleman tarafından geliştirilen R programlama

dili son yıllarda veri işleme, istatistiksel analiz ve veri bilimi için kullanılan popüler araçlardan biri olmuştur (Omar ve Peter, 2017).

R, istatistiksel hesaplama, veri tamamlama, analiz ve görselleştirme için güçlü bir programlama dili ve ortamıdır. Açık kaynak kodludur, kullanıcıların ve geliştiricilerin deneyimlerini paylaştığı binlerce yazılım paketinin geliştirilmesine aktif olarak katkıda bulunduğu, güçlü ve hızlı büyüyen bir topluluğa sahiptir. MATLAB ve SAS gibi diğer bazı ünlü istatistiksel yazılımlarla karşılaştırıldığında R, çok daha basit, kullanıma hazır, ulaşılması daha kolay ve ücretsizdir (Ren, 2016).

2.10. LİTERATÜR ARAŞTIRMASI

Hava kalitesi tayininde ölçümü yapılan kirleticilerin ölçüm sonuçlarının bulunmasında matematiksel modeller kullanılır olduğu gibi teknolojinin gelişimi ile sonuçların bulunmasında yapay zekâ modelleri de kullanılmaya başlanmıştır. İnsanoğlu fiziksel fayda sağlamak adına sürekli yenilikler peşinde uğraş vererek otomatik sistemler üzerinde araştırma yapmış, modeller, tasarımlar ve icatlar geliştirmiştir. Teknolojinin ilerlemesi ile günümüzde fiziksel fayda amaçlı modeller yerine mantık, tahmin, önerme yapan modeller geliştirilmeye başlanmıştır. İnsan zekasını taklit eden modellerin gelişimi ile yapay zekalı akıllı sistemler, robotlar, karar verici sistemler yaratılmaya başlanmış, insanlara karar vermede, anlamsal çıkarımlar yapmada, nesne tanımada kolaylık sağlanmıştır.

Bu tez çalışmasına benzer olarak yapılan araştırmalarda görülmüştür ki farklı kirletici ve/veya meteorolojik veriler, hava kalite indeksi vb. veriler tek veya birden fazla yapay zekâ metodu ile modellenmiş ve en başarılı tahmin modeli tespit edilmeye çalışılmıştır.

Chen ve diğ. (2018) çapı 2,5 μm'den küçük partikül madde ($PM_{2.5}$) konsantrasyonlarının 2005-2016 yılları arasındaki günlük değerlerini, makine öğrenmesi yöntemi kullanarak tahmin etmeye çalışmışlar. Bu çalışma için 2014-2016 yılları arası günlük $PM_{2.5}$ konsantrasyon verileri kullanılmıştır. Yapılan çalışmada geleneksel regresyon modellerine göre daha yüksek tahmin doğruluğu sonuçları elde edilmiştir. Gelecekte hava kirliliğinin önlenmesi ve kontrolü için değerli bilgiler ve kanıtlar sağlandığı kanısına varılmıştır.

Kunt (2014) bulanık mantık ve yapay sinir ağları model yapısını kullanarak Konya il merkezi hava kirliliği modellemesi yapmıştır. Kirletici verileri olarak SO_2, NO_2, O_3 verileri ile basınç,

sıcaklık, rüzgâr hızı, nem, güneş radyasyonu, toplam güneşlenme süresi, yağış, bulut yüksekliği verileri kullanılmıştır. Bu çalışmada modellemede kullanılan YSA ve ANFIS modelleri ile oldukça başarılı sonuçlar elde edilmiştir.

Zhang ve Ding (2017) yaptığı çalışmada, 2010-2015 yılları arasındaki 6 yıllık 5 hava kirliliği parametresini iki ayrı ölçüm istasyonundan temin etmiştir. Bu veriler NO_2, NO_x, O_3, $PM_{2.5}$, SO_2'nin 24 saatlik ortalama verileridir. Meteorolojik veri olarak günlük minimum sıcaklık, maksimum sıcaklık, sıcaklık farkı, ortalama sıcaklık, rüzgâr hızı, rüzgâr yönü, nem verileri günlük, haftalık ve aylık olmak üzere 3 ayrı modelde kullanılmıştır. Bu çalışmada MATLAB yazılımından yararlanılarak üç farklı yöntem kullanılmıştır. Bunlar; MLR (Multiple Linear Regression), FFANN-BP (Feedforward Neural Network Based on Back Propagation), ELM'dir. Yapılan çalıma kapsamında R^2, RMSE, IA ve MAE parametrelerinde en iyi sonuç ELM yöntemi ile tespit edilmiştir.

Vong ve diğ. (2014) tarafından yapılan çalışmada 2003 ile 2010 yılları arası ölçülen kirletici konsantrasyonları PM_{10}, NO_2, SO_2, O_3 ve meteorolojik veri olarak atmosferik basınç, sıcaklık, ortalama bağıl nem, rüzgâr hızı, yağış, güneşlenme süresi, rüzgâr yönü ölçümleri ele alınmıştır. MATLAB yazılımı kullanılarak ELM ile SVM modelleri karşılaştırılmıştır. Çalışmada PM_{10} seviyesi tahmin edilmek istenmiş ve ELM modeli daha kısa sürede daha iyi sonuçlar sunmuştur.

Feng ve diğ. (2019) yer yüzeyindeki ozonu (O_3) analiz etmek ve tahmin etmek için WRF-CMAQ, ELM, MLP (Multi-layer Perceptron), RF ve RNN (Recurrent Neural Network) modellerini karşılaştırmıştır. Meteorolojik veri olarak çiğlenme noktası, sıcaklık, bağıl nem, rüzgâr hızı, rüzgâr yönü, yağış, atmosferik basınç, günlük direkt güneş radyasyonu süresi ve kentsel ısı adası verileri kullanılmıştır. Hava kirletici olarak SO_2, NO_2, $PM_{2.5}$, PM_{10}, CO ve UOK (uçucu organik karbon), OFP (ozon oluşum potansiyeli), PEC (propen eşdeğer konsantrasyonu) değerleri ele alınmıştır. Çalışma sonucunda ozon konsantrasyonu için en verimli tahmin modelinin RNN modeli olduğu görülmüştür.

2018 yılında Li ve diğ. (2018) tarafından yapılan çalışmada, 2015 yılının 1 Nisan ile 1 Temmuz tarihleri arasındaki veriler kullanılmıştır. 25 noktada ölçülen $PM_{2.5}$, PM_{10}, CO, NO kirletici konsantrasyonları SVR, ELM, GA-BPNN, WELM, ANFIS, R-ELANFIS ve ANFIS-WELM modelleri ile modellenip karşılaştırılmıştır. En verimli sonuçları ANFIS-WELM modeli sunmuştur.

Dou ve Yang (2018) 8 farklı noktadaki CO_2 kirliliği ölçüm sonuçlarını, hava sıcaklığı, toprak sıcaklığı, net radyasyon, rüzgâr hızı, bağıl nem ve hacimsel toprak nem içeriği verileri ile 10 YSA, 11 ANFIS, 6 ELM ve 3 SVM olmak üzere 30 farklı model ile modellenmiştir. Bu çalışmada MATLAB yazılımı kullanılmıştır. İki yeni yaklaşım olan ELM ve ANFIS'in kara atmosferi karbon akılarını tahmin etmek için geleneksel YSA ve SVM yöntemlerine umut verici bir şekilde tamamlayıcı olabileceği sonucuna varılmıştır.

Deo ve Şahin'in (2015) yaptıkları çalışmada 4 farklı noktadan 1957-2011 yılları arasındaki meteorolojik veriler alınmıştır; bunlar aylık ortalama yağış, aylık ortalama sıcaklık, aylık maksimumu sıcaklık ve aylık minimum sıcaklıktır. Bu verilerin yanı sıra 4 farklı büyük ölçekli iklim modu indeksleri de kullanılmıştır. ELM ve YSA modelleri kullanılarak, MATLAB yazılımı ile modelleme yapılmıştır. YSA'ya göre ELM'nin eğitim hızı 32 kat, test hızı ise 6 kat daha fazla olduğu tespit edilmiştir.

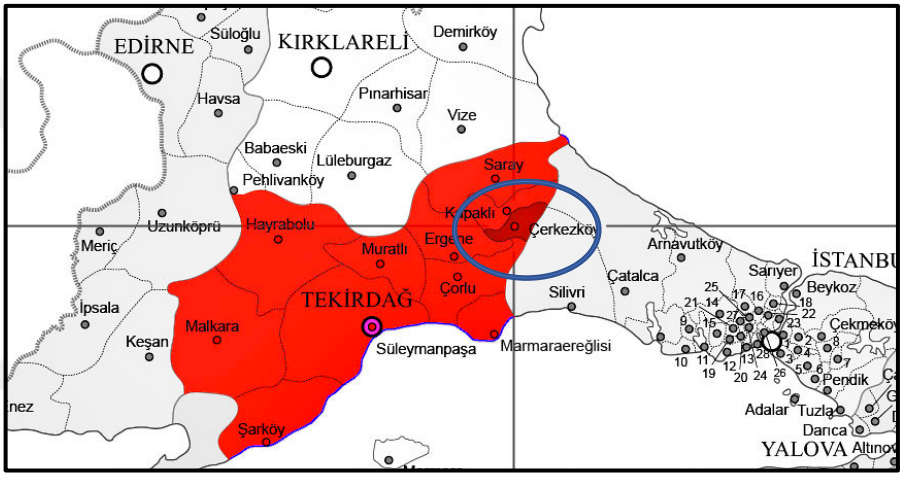
Polezer ve diğ. (2018) tarafından yapılan çalışmada 2008-2011 ve 2014-2015 yılları arası günlük $PM_{2.5}$ kirletici konsantrasyonu ölçüm verileri ele alınmıştır. MLP (Multilayer Perceptron), ELM ve ESN (Echo State Networks) modelleri ile hastane başvuruları, sıcaklık, nem ve $PM_{2.5}$ ilişkisi incelenmiştir. Çalışma sonucunda MLP yönteminin daha uygulanabilir olduğu sonucuna varılmıştır.

Özcan (2016) yaptığı bir çalışmada, önemli bir hava kirletici olan ozon (O_3), başlıca kirletici parametreler ve meteorolojik faktörler ile hücresel yapay sinir ağ (HYSA) yapısı kullanılarak modellenmiştir. Kullanılan parametreler; SO_2, PM, CO, NO, NO_2, O_3, sıcaklık, nem, basınç, güneş süresi, kapalılık, rüzgâr yönü, rüzgâr hızı ve yağıştır. Ozon tahmininde kullanılan atmosferik parametrelerin bir yıllık değişimleri modelde dikkate alınmıştır. Çalışmanın yeni ve değiştirilebilir bir konu ve bu konuda çalışan araştırmacılara örnek olabilecek bir uygulama alanı olduğu sonucuna varılmıştır.

3. YÖNTEM

3.1. ÇALIŞMA BÖLGESİ

Tekirdağ ilinin doğu kesiminde bulunan Çerkezköy ve Kapaklı ilçeleri Karadeniz'e paralel uzanan Yıldız Dağları'nın uzantılarına konumlanmış birbiri ile iç içe olan komşu şehirlerdir (Şekil 3.1). Çerkezköy ilçesine bağlı olan Kapaklı Beldesi 2014 yılında Çerkezköy'den ayrılarak ilçe statüsü kazanmıştır.



Şekil 3.1: Çalışma alanı.

Bölgenin topografyası Çerkezköy-Velimeşe ve Büyükyoncalı-Bahçeağıl doğrultusunda uzanan 50-150 m iki vadi tabanı, dışında ise ortalama 150-200 m ve bazı küçük alanlarda daha fazla yükseltiler ile şekillenmektedir. Genel yerleşim 150-200 m altında yer almakta, yapılaşmanın olmadığı alanlar orman, tarım ve mera alanı olarak kullanılmaktadır. Arazi eğimi ise %5 ile %20 arasında değişmektedir (Çerkezköy, 2021).

Doğu'da Yıldız Dağlarının ve uzantılarının kaplı olduğu orman örtüsü şehir yerleşimine kadar dayanmakta ve şehirleşmenin başlamasıyla bölgenin batısına doğru seyrekleşen orman yerini bozkıra bırakmaktadır. Doğuda yer alan Karadeniz'in etkisiyle Yıldız Dağlarında Karadeniz iklimi görülürken, şehre doğru yağışlar azalmakta, güneyde yer alan Marmara Denizi etkisiyle Marmara kıyılarında Akdeniz iklimini hatırlatsa da buralarda yaz sıcaklıkları düşük seyretmektedir. Batıda Ergene havzasında görülen Marmara bölgesinin en soğuk ve az yağış alan iklimi yer almaktadır. Çerkezköy ve Kapaklı bu üç iklim özelliğinin arasında yer

almaktadır. Marmara geçiş iklimi adını da alan bu iklim kış aylarında Akdeniz iklimi kadar ılık, yaz aylarında ise Karadeniz iklimi kadar yağışlı değilken karasal iklim kadar yazları kurak, kışları ise soğuk geçmemektedir (ÇŞB, 2020).

Bölgede kışın Balkanlardan gelen soğuk hava etkili olurken lodostan eserek Akdeniz'den taşınan ılık hava etkisi de görülmektedir. Yaz aylarında sıcaklık 25 °C ile 30 °C arasında, kış aylarında ise -8 °C ile 10 °C arasında değişmektedir. Hâkim rüzgâr yönü Poyraz ve Yıldız yönlerinde olmakla beraber, Lodosun etkisi de görülmektedir (Çerkezköy, 2021).

2016 yılı TÜİK adrese dayalı nüfus kayıt sistemi verilerine göre 251.562 kişi olan Çerkezköy ve Kapaklı ilçe nüfusları toplamı 2021 yılı verilerinde 327.546 kişiye yükselerek Türkiye ortalaması üzerinde nüfus artışı gözlemlenmiştir (TÜİK, 2021).

Çalışma bölgesinde yer alan Çerkezköy Organize Sanayi Bölgesi'nde (ÇOSB) 287 adet fabrika yer almaktadır. ÇOSB'nin devamı niteliğinde olan Kapaklı Organize Sanayi Bölgesi'nde (KOSB) ise 38 fabrika ve işletme faaliyet göstermektedir. Organize sanayi bölgelerinde faaliyet gösteren fabrika ve işletmelerde yaklaşık 78.000 kişi istihdam edilmektedir (ÇOSB, 2022; KOSB, 2022).

3.2. VERİ SETİ

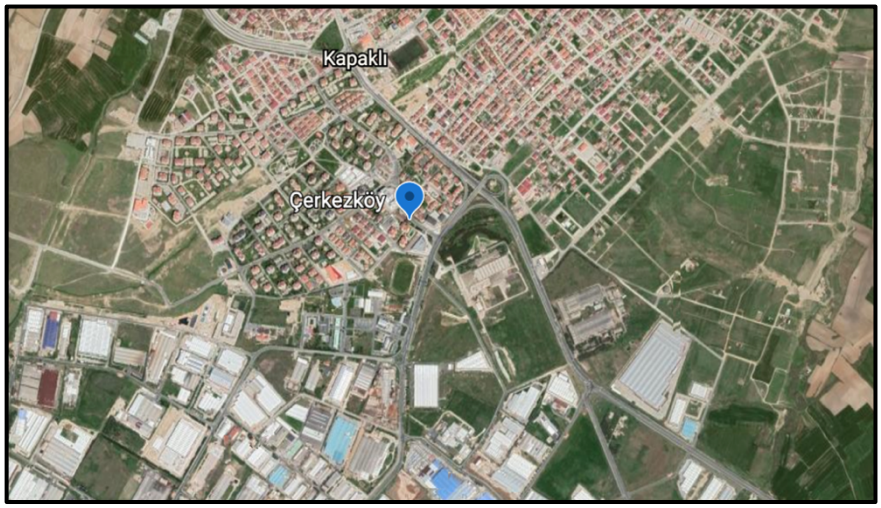
Çalışma kapsamında 01 Ocak 2016 ile 31 Aralık 2019 tarihleri arasındaki 1.384 güne ait SO_2, NO_2, NO, NO_x, CO, PM_{10}, $PM_{2.5}$ hava kirliliği parametreleri ($\mu g/m^3$) ile ortalama sıcaklık (°C), ortalama rüzgâr yönü (°), rüzgâr hızı (m/s), toplam yağış (mm) meteorolojik verileri kullanılmıştır. İstasyona ait veri seti istatistiği Tablo 3.1'de sunulmuştur. Kullanılan veriler günlük ortalama değerlerdir. Kirletici parametrelere ait veriler saatlik ölçüm olarak temin edilmiştir fakat günlük ortalama değerler hesaplanırken sonuçların daha sağlıklı olması için bir güne ait 4 adetten az saatlik veri varsa o gün veri setinden çıkartılmıştır. Ayrıca ölçüm hatası olan veriler hesaba katılmamıştır.

Hava kirliliğine ait istasyon verileri T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Ulusal Hava Kalitesi İzleme Ağı'ndan alınmıştır (SİM, 2020). Marmara Temiz Hava Merkezi bünyesindeki 27,9801 enlem ve 41,3183 boylam konumundaki Çerkezköy istasyonuna ait veriler kullanılmıştır.

Tablo 3.1: Veri seti istatistiği.

	Parametre	Simge	Birim	En Az	En Çok	Ortalama	Std. Sapma
Kirletici Parametreler	**Kükürt dioksit**	SO_2	µg/m³	0,60	155,60	18,67	21,98
	Karbon monoksit	CO	µg/m³	12,80	1968	468	204,07
	Azot dioksit	NO_2	µg/m³	2,60	83,50	24,38	15,88
	Azot oksitler	NO_x	µg/m³	0,70	283,90	44,32	41,60
	Azot monoksit	NO	µg/m³	0,60	151,80	13,44	17,75
Meteorolojik Parametreler	**Sıcaklık**	SIC	ºC	-11	28,10	13,75	7,70
	Rüzgâr yönü	RY	º	1	360	111,80	95,94
	Rüzgâr hızı	RH	m/s	1	10	3,34	1,44
	Toplam yağış	YAĞ	mm	0	60	1,50	4,44
Tahmin Edilen Parametreler	**PM_{10}**	PM_{10}	µg/m³	6,70	248,30	41,25	25,41
	$PM_{2.5}$	$PM_{2.5}$	µg/m³	1,30	100,20	21,35	11,23

Söz konusu ölçüm istasyonu Kapaklı ile Çerkezköy ilçelerinin sınır bölgesinde, şehir kenarında olan site şeklinde yerleşimin olduğu, Çerkezköy Organize Sanayi Bölgesi girişinde yer almaktadır (Şekil 3.2). Konumundan dolayı kentsel hava kirliği ile endüstriyel hava kirliğinin etkisinde olan ve trafikten kaynaklı hava kirliliğinin etkisinin olabileceği bir noktada yer almaktadır. Meteorolojik veriler T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı, Meteoroloji Genel Müdürlüğü, MEVBİS (Meteorolojik Veri Bilgi Satış ve Sunum Sistemi) kayıtlarından temin edilen Çerkezköy ölçüm istasyonuna ait günlük ortalama meteorolojik değerleri içermektedir (MGM, 2020a).

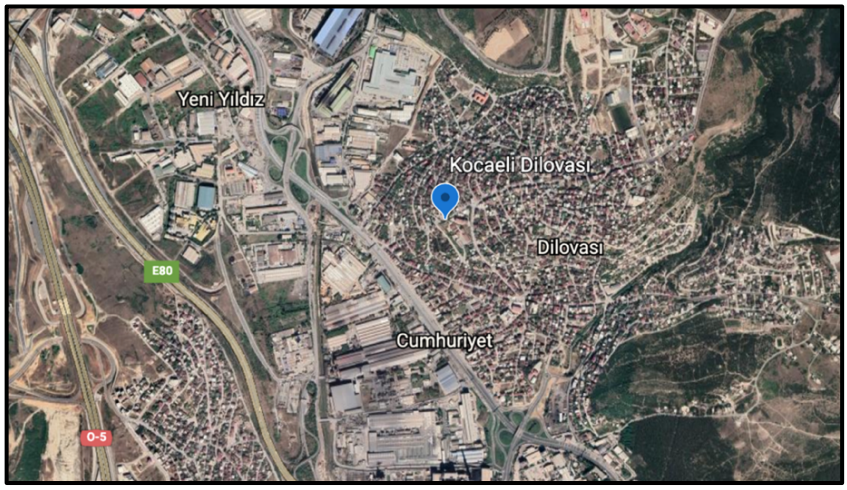


Şekil 3.2: Çerkezköy istasyonunun konumunu gösteren uydu görüntüsü.

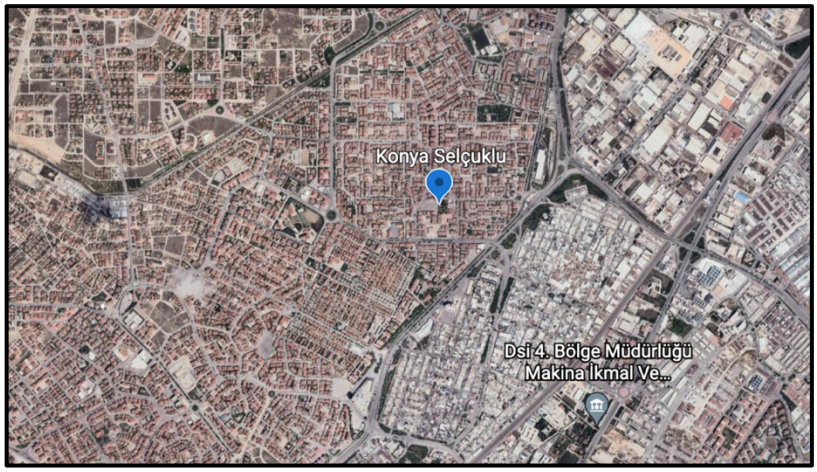
3.3. ÇALIŞMA BÖLGESİ İLE KARŞILAŞTIRILAN BÖLGELER

Bu tez çalışması kapsamında veri temin edilen Çerkezköy hava kalitesi ölçüm istasyonu ülkemizin en büyük organize sanayi bölgelerinden birine çok yakın ve yerleşim alanı içerisinde yer almaktadır. Çerkezköy istasyonuna bu açıdan benzerlik ve zıtlık gösterebilecek ülkemizin farklı coğrafyalarından dört farklı ölçüm istasyonuna ait kirletici konsantrasyon verileri de çalışma süresini kapsayacak şekilde sınır değerlerle kıyaslanmıştır. Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB ve Yalova Armutlu istasyonlarına ait veriler ile Çerkezköy istasyona ait veriler (SİM, 2020) karşılaştırılarak bölgesel farklılıkların ölçüm sonuçları üzerine olabilecek etkileri araştırılmıştır. Kocaeli Dilovası, Konya Selçuklu ve Kayseri OSB istasyonlarının yanı sıra trafik yoğunluğundan, sanayi ve yerleşimden uzak bir noktada konumlandırılmış ölçüm istasyonu olan Yalova ili Armutlu ilçesinde yer alan hava kalitesi ölçüm istasyonu da karşılaştırmaya dahil edilmiştir. Yalova Armutlu hava kalitesi ölçüm istasyonu diğer istasyonlara kıyasla daha temiz hava kalitesine sahip olacağı düşünüldüğünden aralarındaki farkın görülmesi adına yararlı olmuştur. Karşılaştırma kapsamında seçilen istasyonlarda ölçülen PM_{10}, $PM_{2.5}$, SO_2, NO_2 ve NO_x kirleticileri ele alınmıştır.

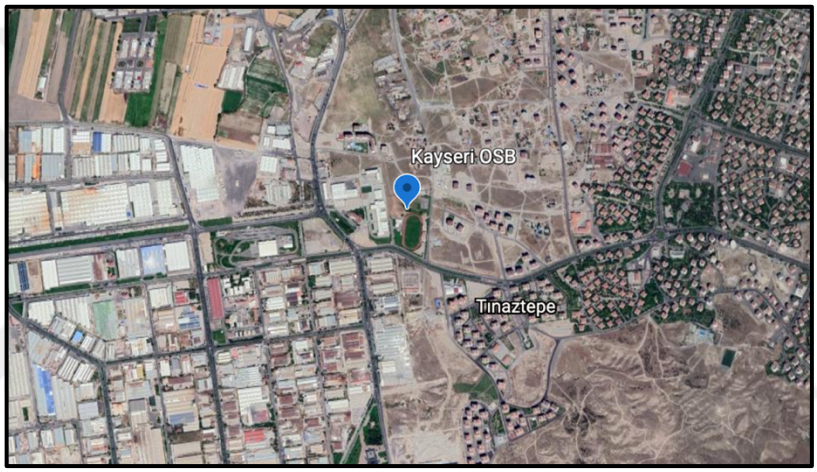
Temel olarak benzer coğrafi konumlandırmalara sahip farklı ölçüm noktalarında ölçülen kirletici konsantrasyonlarına ait değişimlerin olası nedenleri başta antropojenik kaynaklar olan ısınma kaynaklı, ulaşım kaynaklı ve endüstriyel kaynaklı olabileceği gibi, coğrafi, topografik ve iklim vb. doğal kaynaklı da olabilmektedir. Şekil 3.3'te Kocaeli Dilovası, Şekil 3.4'te Konya Selçuklu, Şekil 3.5'de Kayseri OSB ve Şekil 3.6'da Yalova Armutlu istasyonlarına ait uydu görüntüleri yer almaktadır. Uydu görüntülerinde istasyonların şehirleşme, sanayi ve ulaşım açısından konumu görülmektedir.



Şekil 3.3: Kocaeli Dilovası istasyonu konumunu gösteren uydu görüntüsü.



Şekil 3.4: Konya Selçuklu istasyonu konumunu gösteren uydu görüntüsü.



Şekil 3.5: Kayseri OSB istasyonu konumunu gösteren uydu görüntüsü.



Şekil 3.6: Yalova Armutlu istasyonu konumunu gösteren uydu görüntüsü.

3.4. MODEL DEĞERLENDİRME METRİKLERİ

Çalışmada, makine öğrenmesi modellerinin tahmin performansını karşılaştırmak ve değerlendirmek için Korelasyon Katsayısı (Correlation Coefficient, R), Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Ortalama Karesel Hatanın Karekökü (Root Mean Square Error, RMSE) istatistiksel metrikleri kullanılmıştır.

3.4.1. Korelasyon Katsayısı (R)

İki farklı değişkenin arasındaki lineer (doğrusal) ilişkiyi ifade eden katsayıya korelasyon katsayısı denir ve korelasyon katsayısı "R" ile ifade edilir. Korelasyon analinizi ile iki değişken arasındaki ilişkinin yönü ve derecesini belirlenmektedir. Korelasyon katsayısı -1 ile +1 aralığında değer alır. Her iki değişken de aynı yönlü değişikliğe sahipse aralarında pozitif doğrusal ilişki vardır ve korelasyon katsayısı da pozitif (+)'tir. Eğer değişkenlerin biri artarken diğer değişken azalıyorsa değişkenler arasında negatif doğrusal ilişki söz konusudur ve korelasyon katsayısı negatiftir (-)'tir. Değişkenler arasından pozitif veya negatif yönlü bir değişim yok ve değişkenler birbiri ile bağımsız ise değişkenler arasında bir ilişki yoktur, bu durumda korelasyon katsayısı sıfır (0)'dır. Korelasyon katsayısı matematiksel formülü şu şekildedir;

$$\mathrm{R} = \sqrt{1 - \frac{\sum_1^{\mathrm{n}}(o_i - p_i)^2}{\sum_1^{\mathrm{n}}(o_i - o)^2}} \tag{3.1}$$

Eşitlikteki o gerçek değerin ortalama değerini, o_i veri setindeki gerçek değeri, p_i o'nun tahmin edilen değerini, n test veri setinin boyutunu ifade eder (Özcan ve diğ., 2013).

3.4.2. Ortalama Mutlak Hata (MAE)

Ortalama mutlak hata (MAE), tahmin edilen veri ile gerçek veri arasındaki yakınlığı ölçmede kullanılan bir parametredir. Hataların mutlak değerlerinin ortalamasını ifade eder. Ne kadar düşük değere sahip olursa model performansının da o kadar iyi olduğunu göstermektedir (Willmott ve Matsuura, 2005). MAE hesabı aşağıda formüle edilmiştir;

$$\mathrm{MAE} = \frac{1}{\mathrm{n}}\sum_{\mathrm{i}=1}^{\mathrm{n}}|o_i - p_i| \tag{3.2}$$

Eşitlikteki o_i veri setindeki gerçek değeri, p_i o'nun tahmin edilen değerini, n ise test veri setinin boyutunu ifade eder (Guo ve Cui, 2022).

3.4.3. Ortalama Karesel Hatanın Karekökü (RMSE)

Ortalama karesel hatanın karekökü (RMSE), kullanılan bir model sonucu tahmin edilen veriler ile gerçek veriler arasındaki farklılıkları değerlendirmek için kullanılır (Cihan, 2020). Hataların kareköklerinin ortalamasının karekökünü ifade eder (Willmott ve Matsuura, 2005). MAE'de olduğu gibi RMSE'nin de sıfıra yakın olması iyi bir modelin göstergesidir. RMSE ifadesinin matematiksel hali şu şekildedir;

$$\mathrm{RMSE} = \sqrt{\frac{1}{\mathrm{n}}\sum_{\mathrm{i}=1}^{\mathrm{n}}(o_i - p_i)^2} \tag{3.3}$$

Eşitlikteki o_i veri setindeki gerçek değeri, p_i o'nun tahmin edilen değerini, n ise test veri setinin boyutunu ifade eder (Özcan ve diğ., 2013).

3.5. VERİLERİN NORMALİZASYONU

Çalışma kapsamında Min-Max normalleştirme yöntemi kullanılarak veriler normalize edilmiştir. Bu yöntemde veri kümesindeki en düşük değer 0'a ve en yüksek değer 1'e çevrilir. Buna göre diğer tüm veriler de 0-1 arasında bir değere ölçeklendirilir. Bu yöntemdeki amaç en küçük değer 0 ve en büyük değeri 1 olacak şekilde normalleştirmek ve diğer bütün verileri bu 0-1 aralığına yaymaktır. Böylelikle geniş değer aralığına sahip parametreler ile daha dar değer aralığına sahip parametrelerin etkisi aynı düzeye getirilir (Cihan ve diğ., 2017). Özellikle uzaklık ölçüsü kullanan yöntemlerde büyük değere sahip parametrenin yöntem üzerindeki baskısı ortadan kaldırılmış olunur. Normalizasyon işlemine Denklem 3.4'teki gibi hesaplanır (Saylı ve diğ., 2018);

$$\mathrm{X}' = \frac{\mathrm{X}-\mathrm{X}_{\mathrm{min}}}{\mathrm{X}_{\mathrm{max}}-\mathrm{X}_{\mathrm{min}}} \tag{3.4}$$

X' : Normalize edilmiş değer

X : Normalize edilecek değer

X_{min} : Değerler kümesinin minimumu

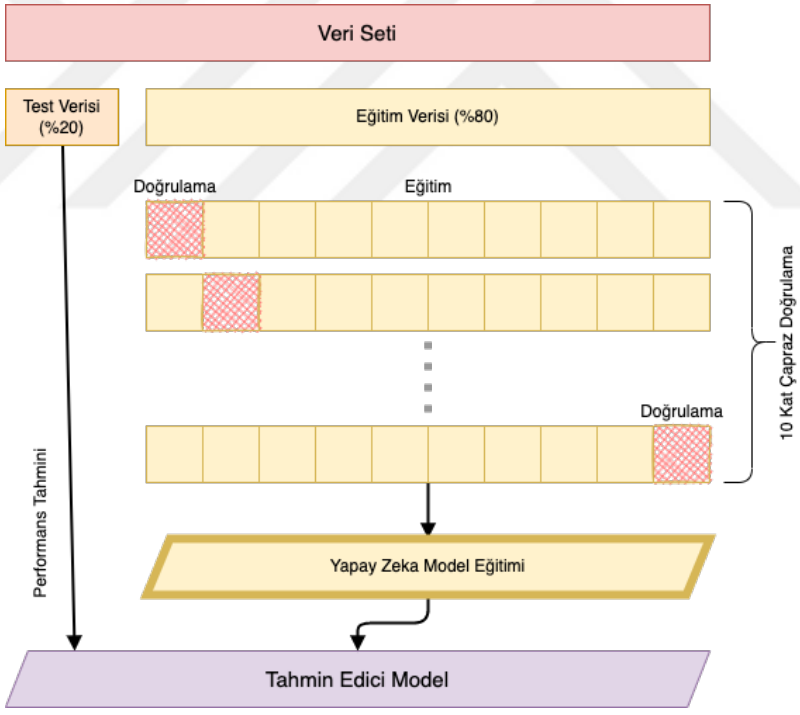
X_{max} : Değerler kümesinin maksimumu

Bu çalışmada, aykırı değerlerin etkisini bastırmak için veriler sınıflandırma aşamasından önce Min-Max normalizasyon yöntemi kullanılarak 0-1 aralığına ölçeklendirilmiştir.

3.6. HAVA KİRLİLECİLER MODELLEME ÇALIŞMASI

Hava kirleticilerin modellenmesi aşamasında aynı girdiye ancak farklı çıktı değişkenlerine (PM_{10} ve $PM_{2.5}$) sahip iki veri seti kullanılmıştır. Veri setindeki değişkenlerin değer aralıkları farklı olduğundan yani normal bir dağılım göstermediğinden giriş değişkenleri normalize edilmiştir. Eksik değerler haftalık ortalama alınarak tamamlanmıştır.

Veri setindeki örneklerin yaklaşık %80'i (1.107 örnek) eğitimi modellemek için, kalan %20'si (277 örnek) ise model tahmin performansını ölçmek için kullanılmıştır. Farklı yapay zekâ modellerinin tahmin performansını karşılaştırmak için veri seti rastgele ama aynı oranda bölünmüştür. Böylece tüm modellerin tahmin performansları aynı test seti üzerinde gerçekleştirilmiştir. Model eğitiminde 10 kat çapraz doğrulama tekniği kullanılmıştır. Bu teknikte 9 alt küme modeli eğitmek için kullanılır ve 1 alt küme test/doğrulama için kullanılır. Bu işlem 10 kez tekrarlanır. Akış diyagramı Şekil 3.7'de verilmiştir.



Şekil 3.7: Akış diyagramı.

Modellerin eğitim süreci tamamlandıktan sonra öğrenilen modeller ile PM_{10} ve $PM_{2.5}$ değerleri tahmin edilmiştir. Tahmin doğruluk performansları, modellerin tahmin ettiği PM değerleri ile gerçek değerleri (RMSE, MAE, R) karşılaştırılarak ölçülmüştür. Yapay zekâ modellerinin geliştirilmesi ve istatistiksel analizler R programlama dili kullanılarak gerçekleştirilmiştir.

Teknolojideki gelişmeler sonucunda eğitilebilir algoritmalar, başarıları nedeniyle hava kalitesi tahmininde yaygın olarak kullanılmaktadır. Bu çalışmada, partikül madde tahmini 6 farklı model ile yapılarak modellerin tahmin başarıları karşılaştırılmıştır. Bu modeller adaptif sinirsel bulanık çıkarım sistemi (ANFIS), destek vektör regresyonu (SVR), kümeleme ve regresyon ağaçları (CART), rastgele orman (RF), k-en yakın komşu algoritması (KNN) ile aşırı öğrenme makinesidir (ELM).

3.7. HAVA KALİTESİ İNDEKSİ VE COVID-19 PANDEMİSİ SÜRECİ

Çalışma kapsamında 1 Ocak 2016 ile 31 Aralık 2019 tarihleri arasındaki 1.460 güne ait hava kalitesi indeksi (HKİ) verileri kullanılmıştır. Kullanılan HKİ değeri günlük HKİ değeridir. Kullanılan HKİ verileri Marmara Temiz Hava Merkezi bünyesindeki Çerkezköy istasyonuna ait veriler olup World's Air Pollution'dan temin edilmiştir (WAP, 2020). Söz konusu istasyon şehir kenarında olan site şeklinde yerleşimin olduğu, Çerkezköy Organize Sanayi Bölgesi girişinde yer almaktadır. Konumundan dolayı kentsel hava kirliği ile endüstriyel hava kirliğinin etkisinde olan ve trafikten kaynaklı hava kirliliğinin etkisinin olabileceği bir noktada yer almaktadır.

HKİ belirlenmesi çalışmalarının bir diğer amacı da COVID-19 pandemisi nedeniyle sokağa çıkma yasağı uygulanan günlerde hava kirliği parametrelerinin değişiminin incelenmesidir. Türkiye'de, 11.04.2020-11.05.2020 tarihleri arasında hafta sonları sokağa çıkma yasağı uygulanmıştır. Bu tarihlerdeki hava kalitesinin bir önceki yıla (11.04.2019-11.05.2019) göre nasıl değişiklik gösterdiği karşılaştırılmıştır (SİM, 2020). Ayrıca pandemi sürecinde yaşanan sokağa çıkma yasağı olduğu aylarda sanayideki üretimin ve tüketimin azalması sonucu tüketilen elektrik ve doğalgaz miktarındaki değişim incelenerek hava kalitesindeki değişimle birlikte yorumlanmıştır. İncelenen elektrik ve doğalgaz tüketim değerleri ÇOSB web sitesinden temin edilmiştir (ÇOSB, 2020).

4. BULGULAR

Bu tez çalışmasında, Çerkezköy hava kalitesi ölçüm istasyonunda ölçülen PM_{10} ve $PM_{2.5}$ kirleticilerine ait verilerin eğitilebilir algoritmalar kullanılarak tahmin edilmesi amaçlanmıştır.

Bu amaçla çalışmanın birinci aşamasında PM_{10} ve $PM_{2.5}$ başta olmak üzere hava kirletici verileri ve meteorolojik verilerden oluşan veri seti incelenmiş, verilerin zamansal analizi yapılmıştır. İkinci aşamada ise hava kirletici ve meteorolojik verilerden oluşan veri tabanı kullanılarak partikül madde (PM_{10}, $PM_{2.5}$) konsantrasyonlarının tahmini 6 farklı makine öğrenmesi tekniği ile gerçekleştirilmiştir.

4.1. HAVA KALİTESİNİN İNCELENMESİ

4.1.1. Verilerin Yıllık Dağılımı

Meteoroloji Genel Müdürlüğü'nden temin edilen Tekirdağ iline ait genel istatistiki veriler Tablo 4.1'de sunulmuştur. Genel istatistiki verilerin ölçüm periyodu 1939 ile 2020 yılları aralığındadır (MGM, 2021b).

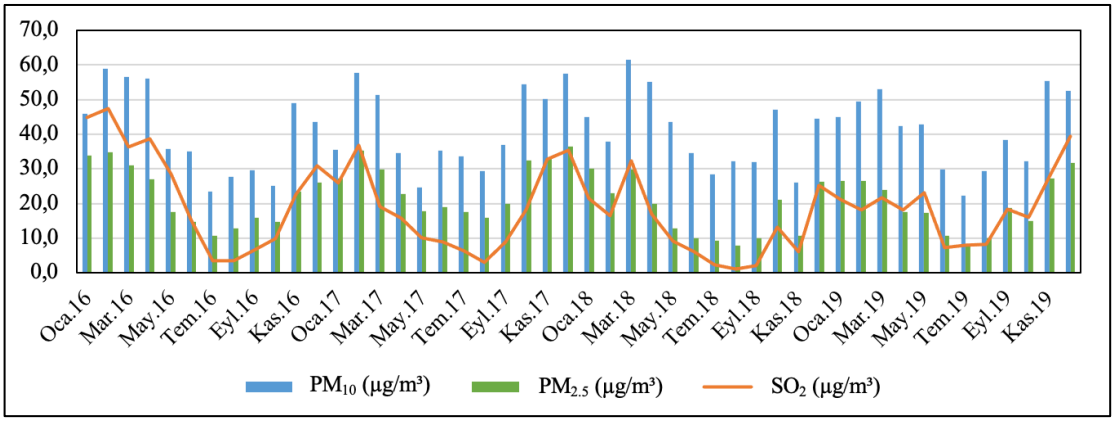
1929-2020 yılları arası yapılan ölçümlerde Tekirdağ iline ait yıllık ortalama sıcaklık 14,1 °C olup, 4,8 °C'lik en düşük sıcaklık ortalamasının Ocak ayında ve 23,8 °C'lik en yüksek sıcaklık ortalamasının ise Ağustos ayında ölçüldüğü Tablo 4.1'de görülmektedir.

Yıllık ortalama yağışlı gün sayısı 110,1 gün olarak tespit edilirken, en fazla ortalama yağışlı gün sayısı 13,6 gün ile Ocak ayında, en düşük ortalama yağışlı gün sayısı ise 3,1 gün ile Ağustos ayında görülmüştür. Aylık toplam yağış miktarları ortalaması incelendiğinde en fazla yağışın olduğu ay 80,7 mm ile Aralık ayındadır. En az aylık toplam yağış miktarı ortalaması 15,3 mm yağış ile Ağustos ayında tespit edilmiştir. En düşük ve en yüksek aylık ortalama sıcaklık ile ortalama yağışlı gün sayısı aynı aylar olan Ocak ile Ağustos ayında tespit edilmiştir. Aylık toplam yağış miktarı ortalamaları incelendiğinde Aralık ve Kasım aylarında Ocak ayından daha fazla miktarda yağışın olduğu kayıtlara geçmiştir.

Tablo 4.1: Tekirdağ iline ait genel istatistiki veriler (1939-2020 yılları arası).

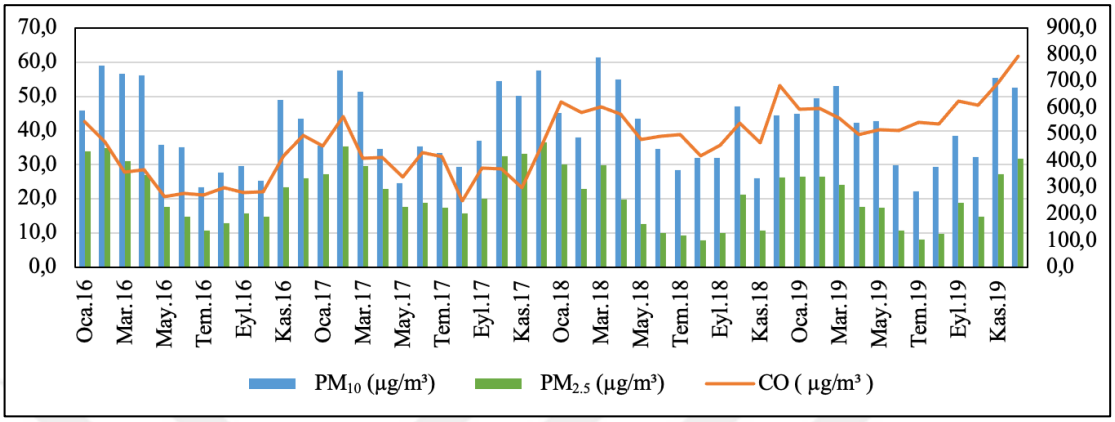
TEKİRDAĞ	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık	Yıllık
Ortalama Sıcaklık (°C)	4,8	5,4	7,3	11,7	16,7	21,1	23,7	23,8	20,2	15,6	11,2	7,2	14,1
Ortalama En Yüksek Sıcaklık (°C)	8,0	9,0	11,1	15,7	20,6	25,3	28,0	28,2	24,5	19,5	14,8	10,4	17,9
Ortalama En Düşük Sıcaklık (°C)	1,9	2,4	4,1	8,1	12,7	16,7	19,0	19,3	16,1	12,1	8,1	4,3	10,4
Ortalama Güneşlenme Süresi (saat)	2,7	3,3	4,3	5,9	7,4	8,7	9,6	8,7	7,0	4,8	3,3	2,5	5,7
Ortalama Yağışlı Gün Sayısı	13,6	11,5	11,8	10,2	9,5	8,1	4,0	3,1	5,2	8,7	10,9	13,5	110,1
Aylık Toplam Yağış Miktarı Ortalaması (mm)	68,3	54,5	54,0	41,1	37,4	38,3	24,4	15,3	33,7	61,9	73,5	80,7	583,1
En Yüksek Sıcaklık (°C)	23,9	24,7	28,1	34,3	33,8	40,2	38,4	37,5	39,7	35,1	27,9	23,5	40,2
En Düşük Sıcaklık (°C)	-13,5	-13,3	-10,4	-1,2	2,7	8,6	10,9	11,0	3,7	-1,8	-7,8	-10,9	-13,5

PM_{10} ve $PM_{2.5}$ aylık ortalama konsantrasyonlarının SO_2 ile değişimi Şekil 4.1'de, CO ile değişimi Şekil 4.2'de, NO_2 ile değişimi Şekil 4.3'te, NO_x ile değişimi Şekil 4.4'te, NO ile değişimi Şekil 4.5'te, ortalama sıcaklık ile değişimi Şekil 4.6'da, rüzgar yönü ile değişimi Şekil 4.7'de, rüzgar hızı ile değişimi Şekil 4.8'de, toplam yağış ile değişimi Şekil 4.9'da sunulmuştur.

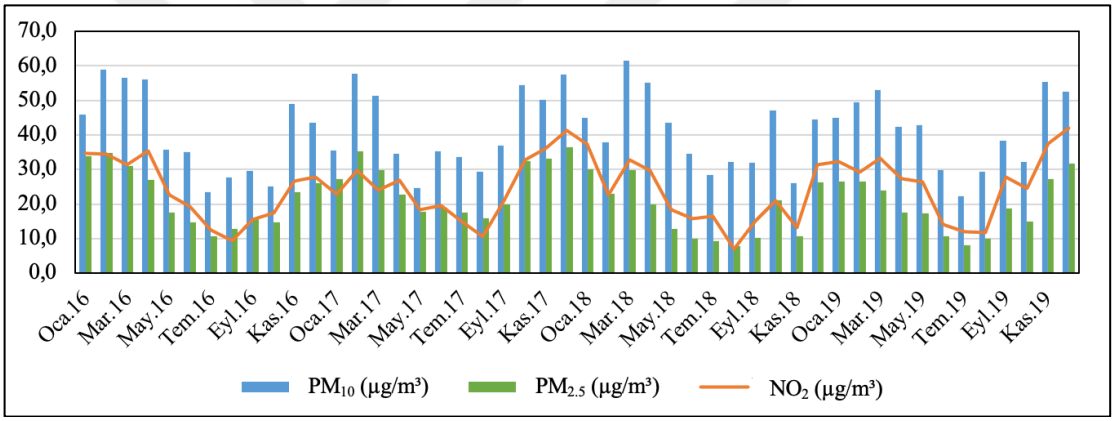


Şekil 4.1: PM_{10}, $PM_{2.5}$ ve SO_2 aylık değişim grafiği.

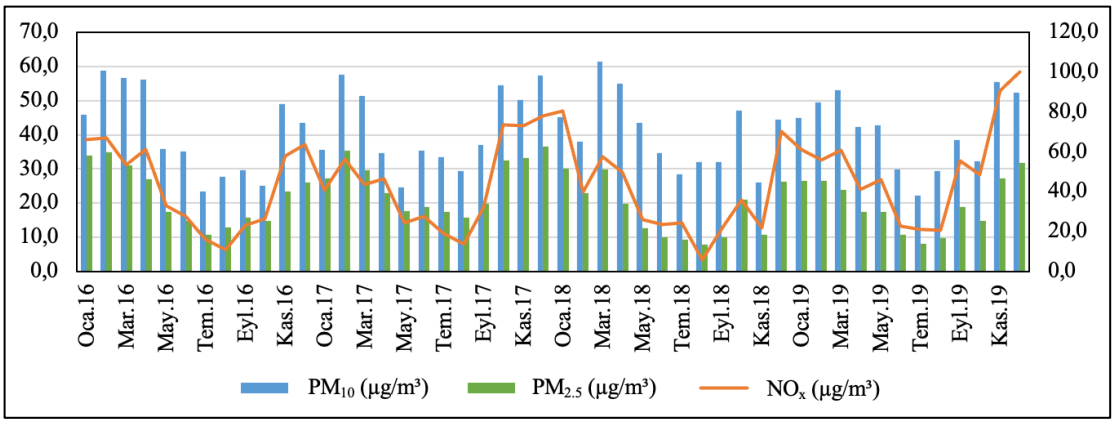
PM_{10} ve $PM_{2.5}$ konsantrasyonundaki değişimle SO_2 konsantrasyonunda görülen pozitif yönlü değişim, bu kirleticiler arasında pozitif korelasyonun olduğunu göstermektedir (Şekil 4.1). Ayrıca PM ve SO_2 kirliliği kaynağının aynı kaynak olduğu da söylenebilir.



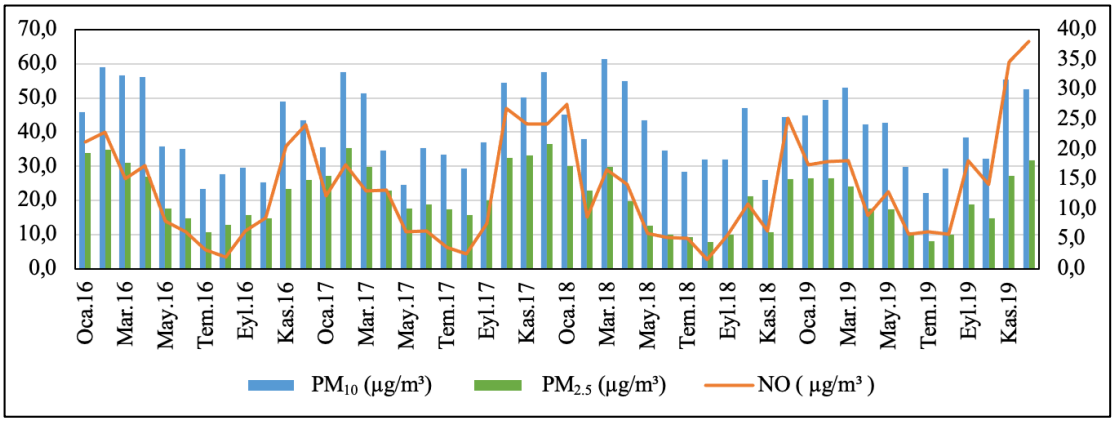
Şekil 4.2: PM_{10}, $PM_{2.5}$ ve CO aylık değişim grafiği.



Şekil 4.3: PM_{10}, $PM_{2.5}$ ve NO_2 aylık değişim grafiği.

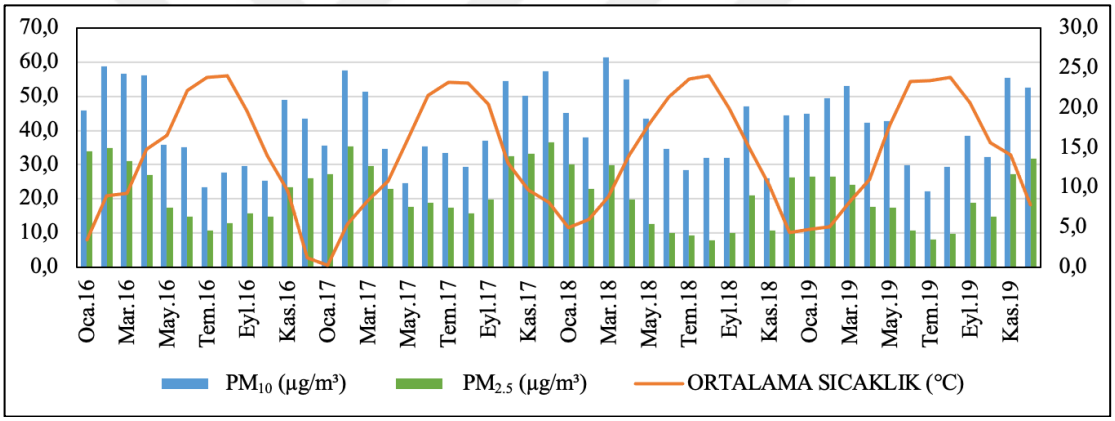


Şekil 4.4: PM_{10}, $PM_{2.5}$ ve NO_x aylık değişim grafiği.



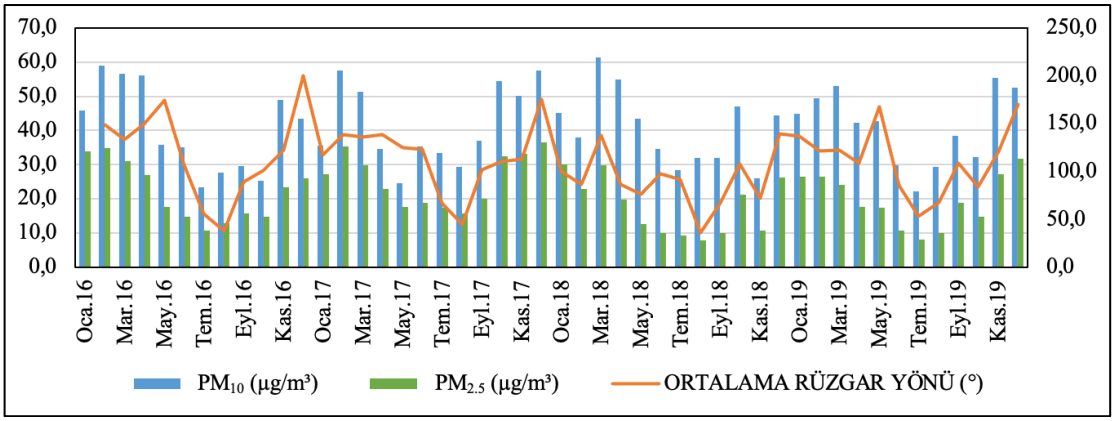
Şekil 4.5: PM_{10}, $PM_{2.5}$ ve NO aylık değişim grafiği.

NO, NO_x ve NO_2 konsantrasyonlarındaki değişime paralel olarak PM konsantrasyonları da değişmektedir (Şekil 4.3, Şekil 4.4, Şekil 4.5). Aralarında pozitif korelasyon olduğu görülen kirleticilerin ulaşım kaynaklı olduğu bilinmektedir.

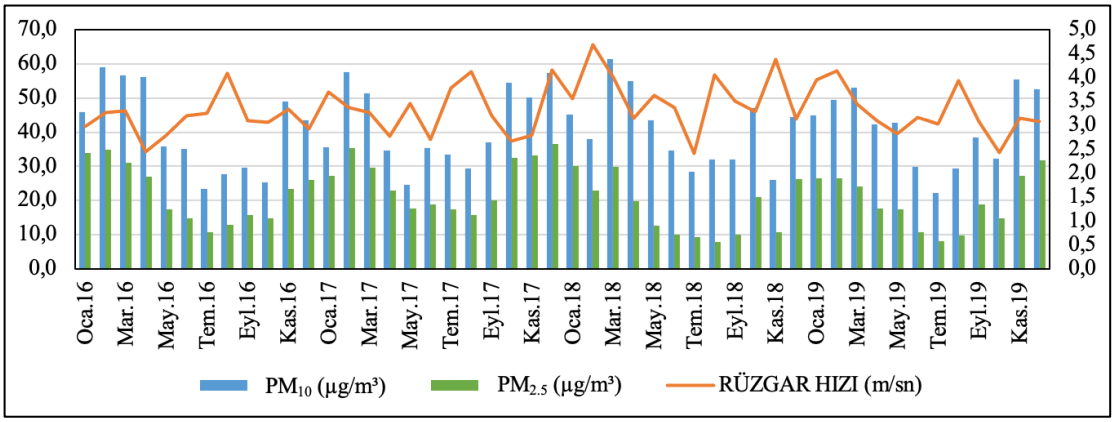


Şekil 4.6: PM_{10}, $PM_{2.5}$ ve ortalama sıcaklık aylık değişim grafiği.

Sıcaklığın artış gösterdiği aylarda PM konsantrasyonunda görülen azalış ısınma kaynaklı kullanılan fosil yakıtların PM kirliliğine neden olduğunu göstermektedir (Şekil 4.6).

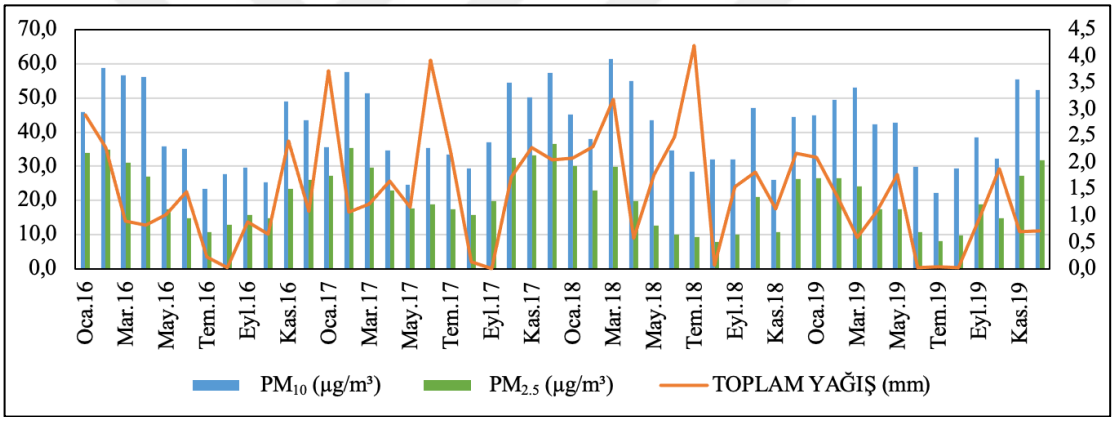


Şekil 4.7: PM_{10}, $PM_{2.5}$ ve ortalama rüzgâr yönü aylık değişim grafiği.



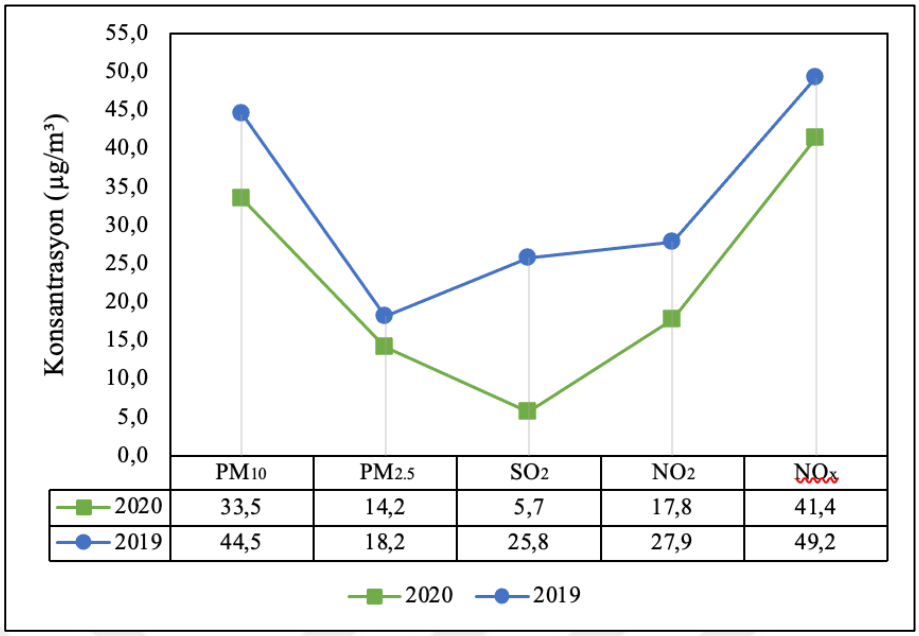
Şekil 4.8: PM_{10}, $PM_{2.5}$ ve rüzgâr hızı aylık değişim grafiği.

Rüzgâr hızının artışı kirleticilerin dağılımını olumlu yönde etkileyen bir faktördür. Rüzgâr yönü ise emisyon kaynaklarının tayininde yol gösterici olmaktadır (Şekil 4.7). Ayrıca havadaki kirleticilerin yere çökmesinde yağışın olumlu etkisi olmaktadır.



Şekil 4.9: PM_{10}, $PM_{2.5}$ ve toplam yağış aylık değişim grafiği.

COVID-19 pandemisi nedeniyle 11.04.2020-11.05.2020 tarihleri arasında hafta sonları Türkiye'de sokağa çıkma yasağı uygulanmıştır. Bu tarihler ile geçen senenin aynı dönemi olan 11.04.2019-11.05.2019 tarihleri arasındaki Çerkezköy istasyonuna ait hava kalitesi değişimi Şekil 4.10'da verilmiştir.

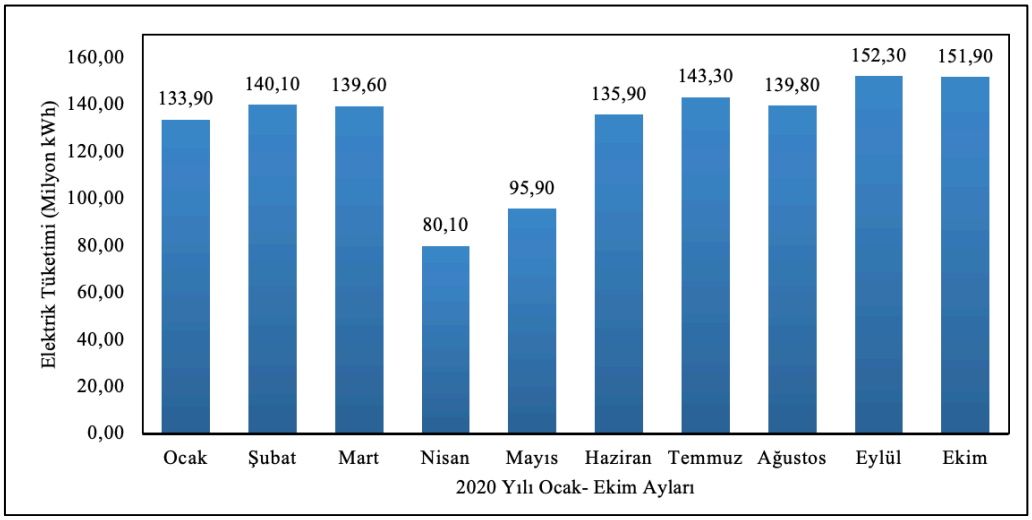


Şekil 4.10: 2019-2020 yılları arası hava kalitesi değişimi.

Şekil 4.10 incelendiğinde sokağa çıkma yasaklarının uygulandığı 2020 yılında, kirletici konsantrasyonu ölçüm değerleri, bir önceki yıla göre düşüş gösterdiği görülmektedir. En fazla düşüş SO_2 parametresinde görülmekte olup 11.04.2019-11.05.2019 arasında ortalama 25,8 µg/m³ iken 11.04.2020-11.05.2020 arasında 5,7 µg/m³'e düştüğü görülmektedir. PM_{10} değerinin 44,5 µg/m³'ten 33,5 µg/m³'e, $PM_{2.5}$ değerinin 18,2 µg/m³'ten 14,2 µg/m³'e, NO_2 değerinin 27,9 µg/m³'ten 17,8 µg/m³'e ve NO_x değerinin 49,2 µg/m³'ten 41,4 µg/m³'e düştüğü görülmüştür. Sonuç olarak COVID-19 salgınında sokağa çıkma yasakları, tüm hava kirletici konsantrasyonu ölçüm değerlerinde bir düşüş sağlamıştır.

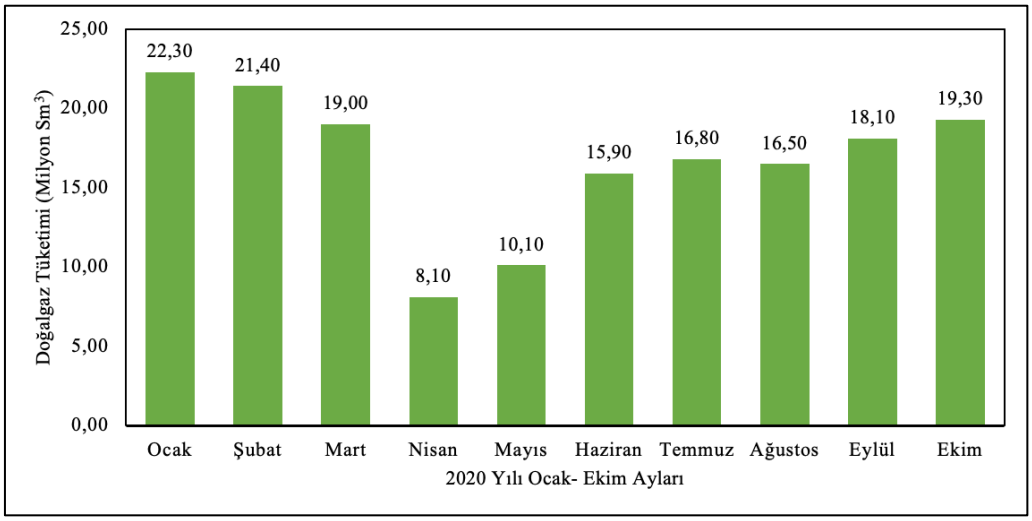
Tez kapsamında hava kalitesi ölçüm verilerinin temin edildiği ölçüm istasyonu ile aynı konumda yer alan Çerkezköy Organize Sanayi Bölgesinin 2020 yılının Ocak-Ekim dönemi arası elektrik tüketim değerleri Şekil 4.11'de ve doğalgaz tüketim değerleri Şekil 4.12'de sunulmuştur (ÇOSB, 2020).

ÇOSB'ye ait elektrik tüketim değerleri incelendiğinde Ocak-Mart ayları arasında 133,9-139,6 milyon kWh aralığında olan elektrik tüketim miktarı Nisan ayında COVID-19 pandemi kısıtlaması nedeniyle 80,1 milyon kWh'ye düşmüştür. Bu da ÇOSB'de üretimin azaldığını açıkça göstermektedir. Pandemi kısıtlamalarının gevşetilmesi ile Mayıs ayında elektrik tüketim miktarı 95,9 milyon kWh'ye yükselmiş ve Haziran ayından itibaren pandemi öncesi tüketim değerlerine ulaşmıştır.



Şekil 4.11: ÇOSB elektrik tüketim değerleri.

ÇOSB bünyesinde kullanılan doğalgaz tüketim değerleri 2020 yılının Ocak-Ekim ayları arası incelendiğinde elektrik tüketim değerlerine paralel bir değişim gözlemlenmektedir. Ocak-Mart ayları arasında 22,3-19,0 milyon Sm^3 aralığında azalan bir tüketimin ardından Nisan ayında tüketimde yaşanan düşüşle 8,1 milyon Sm^3 değerine inen tüketim miktarı Mayıs ayında 10,1 milyon Sm^3 değerine yükselmiştir. Mayıs ayının ardından gelen aylarda doğalgaz tüketimi, 15,9-19,3 milyon Sm^3 aralığında paralel bir değişim sergilemiştir.



Şekil 4.12: ÇOSB doğalgaz tüketim değerleri.

Şekil 4.10'de yer alan 2019-2020 yılları Nisan-Mayıs dönemi hava kalitesi değişimi ile Şekil 4.11 ve Şekil 4.12'de yer alan ÇOSB elektrik ve doğalgaz tüketim değerleri karşılaştırıldığında; 2020 yılında yaşanan COVID-19 pandemisi sonucu sanayide kullanılan elektrik ve doğalgaz tüketimindeki azalış, 2019 yılındaki hava kalitesi değerleri ile 2020 yılına ait hava kalitesi değerleri arasındaki farkın oluşmasına neden olduğunu göstermektedir. 2019 yılına göre 2020

yılı Nisan-Mayıs döneminde hava kirliğine etken olan kirletici konsantrasyon miktarlarında azalma gözlemlenmiş olup, hava kalitesi bakımından olumlu sonuçlar oluşmuştur.

4.1.2. Verilerin Mevsimlik Dağılımı

2007-2020 yılları arasında Tekirdağ iline ait mevsim normalleri Tablo 4.2'de yer almaktadır, mevsim normalleri tablosunda yer alan verilerinde ise son iklim periyodu 2007 ile 2020 yılları aralığındadır. Mevsim normalleri ortalama sıcaklık değeri Ocak ayında 5,2 °C'ye kadar inerken Ağustos ayında 24,8 °C'ye kadar çıkmaktadır. Mevsim normallerinde yıllık ortalama sıcaklık ise 14,5 °C'dir.

Yağış, havadaki kirleticilerin çökelmesine ve havadaki konsantrasyonun azalmasına neden olmaktadır. Mevsim normallerine göre ortalama yağışlı gün sayısı en fazla 13 gün ile Aralık ayında (1939-2020 dönemi verilerine göre 13,6 gün ile Ocak ayıdır), en az 3 gün ile Ağustos ayında görülmüştür. Aylık toplam yağış miktarı ortalamaları incelendiğinde mevsim normalleri yıllık 601,1 mm olarak tespit edilmiştir. 1939-2020 yılları arasında toplam yağış miktarı olan 583,1 mm'lik yağış miktarında artış gözlemlendiği görülmektedir. En fazla yağış miktarı ortalamasına sahip olan ay 81,6 mm ile Ekim ayı (1939-2020 dönemi verilerine göre 80,7 mm'lik yağış ile Aralık ayıdır), en az yağış miktarı ortalamasına sahip ay ise 16,4 mm ile Ağustos ayı olarak ölçülmüştür (MGM, 2021c).

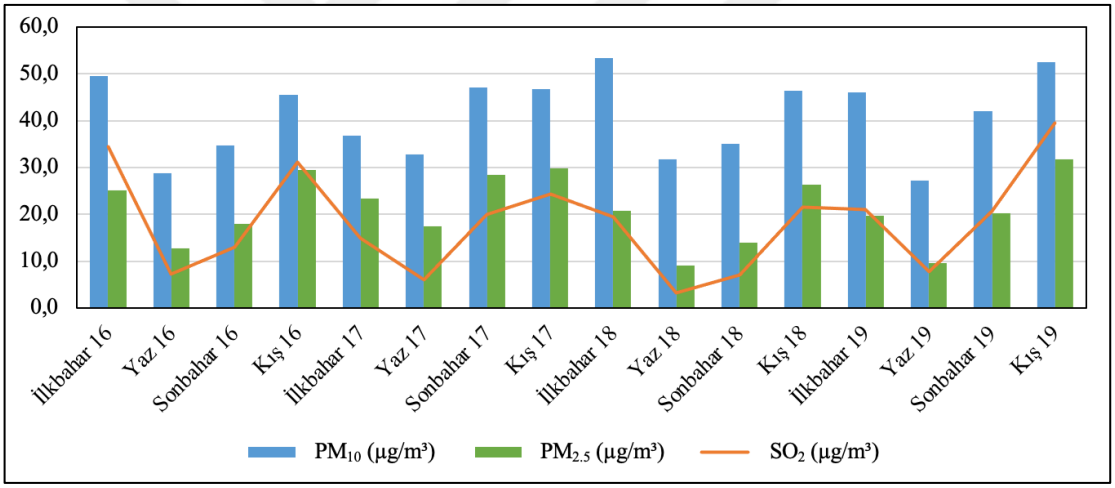
Tablo 4.2: Tekirdağ iline ait mevsim normalleri.

TEKİRDAĞ	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık	Yıllık
Ortalama Sıcaklık (°C)	5,2	5,8	8,1	12,0	17,1	21,8	24,4	24,8	20,7	16,1	11,4	7,1	14,5
Ortalama En Yüksek Sıcaklık (°C)	8,6	9,4	12,0	16,1	21,2	26,0	28,7	29,1	25,1	20,0	15,1	10,4	18,5
Ortalama En Düşük Sıcaklık (°C)	2,4	2,8	4,8	8,4	13,1	17,4	19,8	20,5	16,7	12,7	8,2	4,2	10,9
Ortalama Güneşlenme Süresi (saat)	2,7	3,5	4,4	6,0	7,5	8,8	9,6	8,7	6,9	4,7	3,3	2,5	5,7
Ortalama Yağışlı Gün Sayısı	12,3	11,3	12,3	10,7	9,8	7,7	3,9	3,0	6,2	9,2	9,7	13,0	109,0
Aylık Toplam Yağış Miktarı Ortalaması (mm)	58,2	62,7	53,7	40,8	37,8	37,9	28,5	16,4	45,7	81,6	61,2	76,6	601,1

PM_{10} ve $PM_{2.5}$ mevsimsel ortalama konsantrasyonlarının SO_2 ile değişimi Şekil 4.13'te, CO ile değişimi Şekil 4.14'te, NO_2 ile değişimi Şekil 4.15'te, NO_x ile değişimi Şekil 4.16'da, NO ile değişimi Şekil 4.17'de, ortalama sıcaklık ile değişimi Şekil 4.18'de, rüzgar yönü ile değişimi Şekil 4.19'da, rüzgar hızı ile değişimi Şekil 4.20'de, toplam yağış ile değişimi Şekil 4.21'de sunulmuştur.

Hazırlanan şekillerde 2016 kış dönemi; 2016 yılı Aralık ayı, 2017 yılı Ocak ve Şubat aylarını kapsamaktadır. Diğer yıllardaki kış mevsimi de benzer şekilde ortalamalar hesaplanarak devam etmiştir. 2019 yılı kış ayı sadece 2019 yılı Aralık ayını kapsamaktadır.

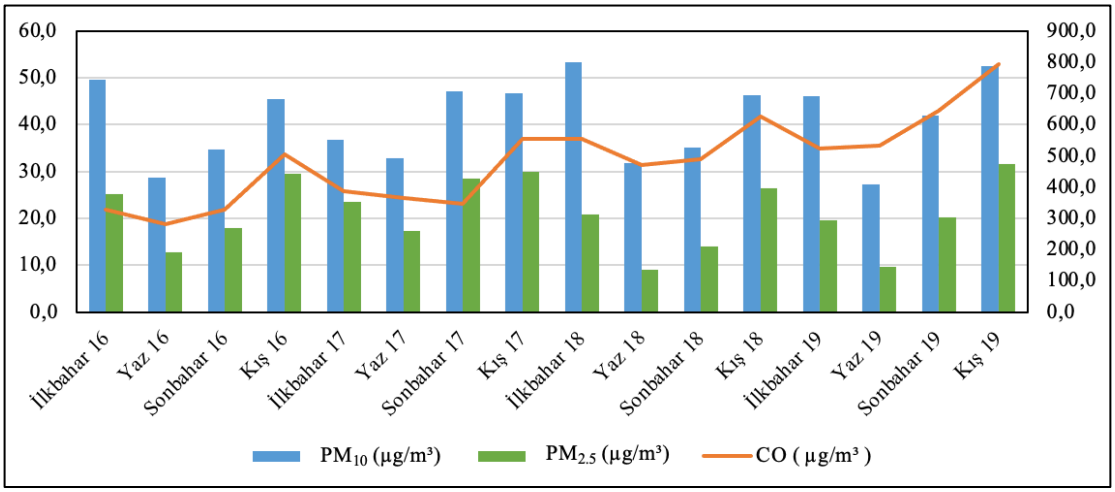
Mevsimsel SO_2 konsantrasyonları ile PM konsantrasyonlarının Şekil 4.13'te paralel hareket ettiği görülmektedir. Isınmadan kaynaklı SO_2 ve PM kirliliğinin çalışma bölgesinde varlığı söylenebilir.



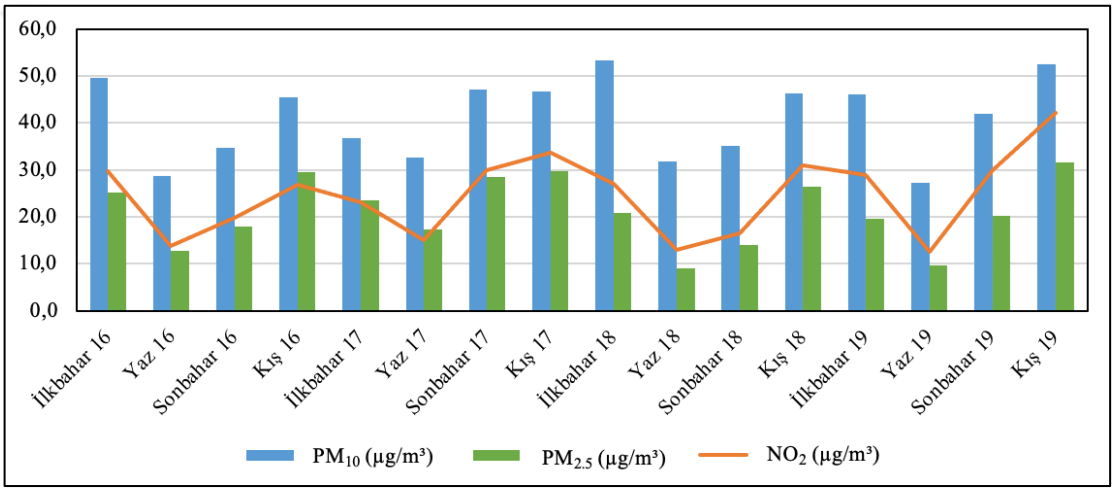
Şekil 4.13: PM_{10}, $PM_{2.5}$ ve SO_2 mevsimsel değişim grafiği.

2016 yılından 2019 yılına gelindiğinde CO konsantrasyonunda kademeli artışın olduğu görülmektedir (Şekil 4.14). Eksik yanma ürünü olarak oluşan CO varlığı, ısınmadan kaynaklı ve ulaşımdan kaynaklı kirliliğin artış gösterdiğini ifade etmektedir.

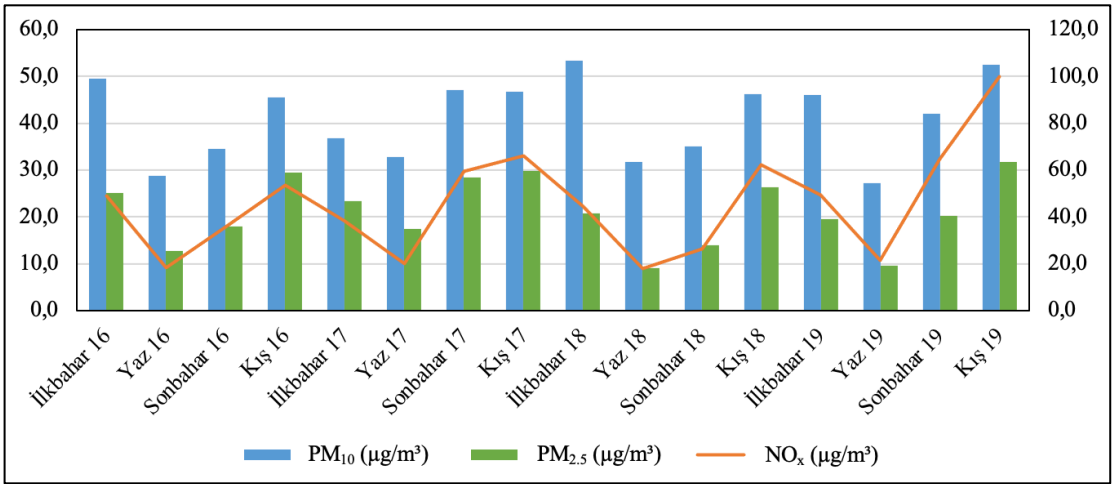
PM konsantrasyonu ile NO, NO_x ve NO_2 konsantrasyonları aylık değişim grafiklerinde olduğu gibi mevsimlik grafikte de korelasyon içindedir. Kış aylarında ulaşımdan kaynaklı hava kirliliğinin varlığı yaz aylarına göre daha fazladır (Şekil 4.15, Şekil 4.16, Şekil 4.17).



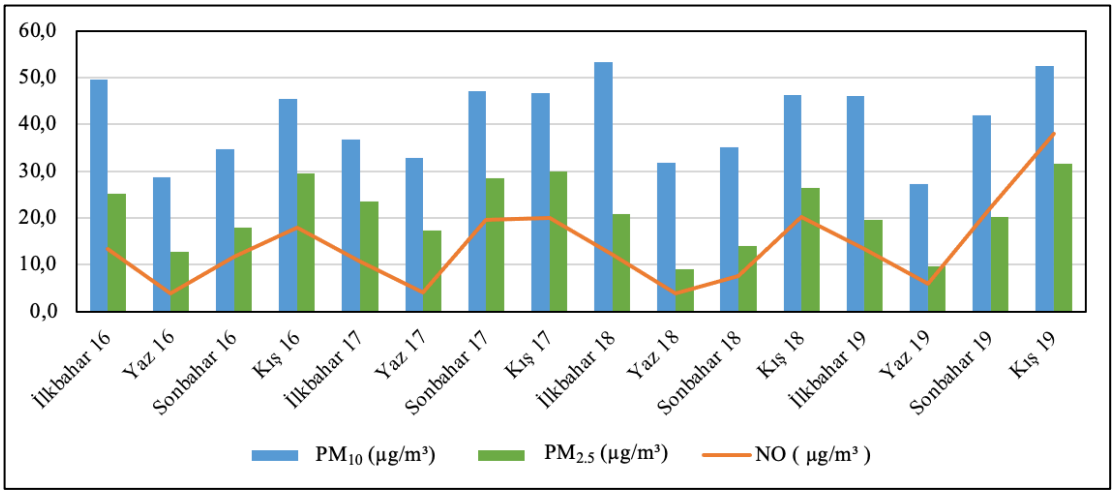
Şekil 4.14: PM_{10}, $PM_{2.5}$ ve CO mevsimsel değişim grafiği.



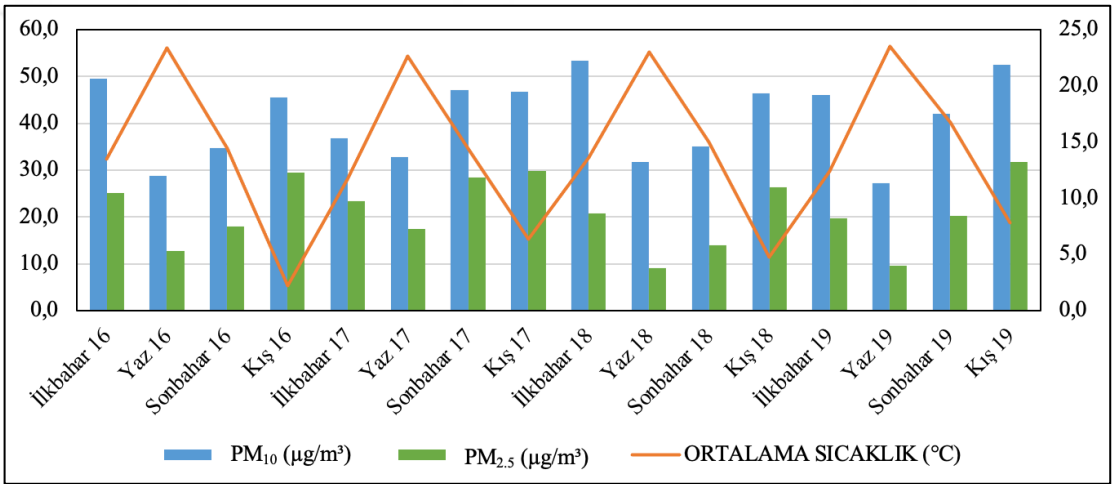
Şekil 4.15: PM_{10}, $PM_{2.5}$ ve NO_2 mevsimsel değişim grafiği.



Şekil 4.16: PM_{10}, $PM_{2.5}$ ve NO_x mevsimsel değişim grafiği.



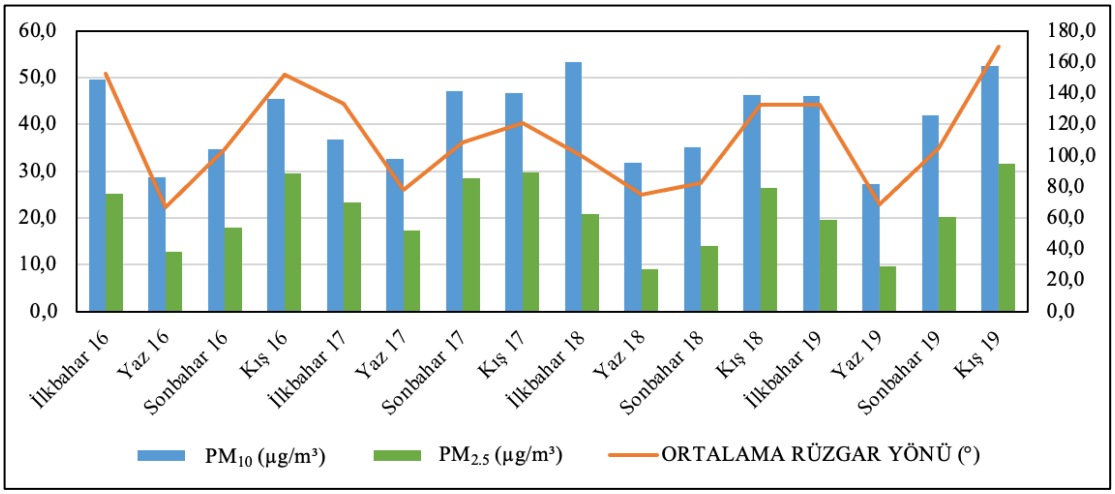
Şekil 4.17: PM_{10}, $PM_{2.5}$ ve NO mevsimsel değişim grafiği.



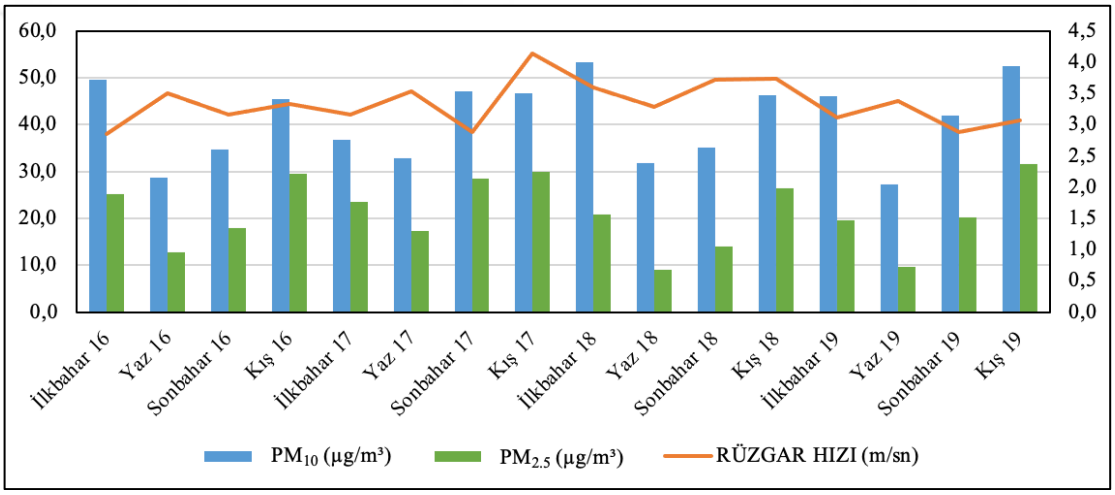
Şekil 4.18: PM_{10}, $PM_{2.5}$ ve ortalama sıcaklık mevsimsel değişim grafiği.

Yaz aylarında hâkim rüzgar yönünün kış aylarına göre farklılık gösterdiği gözlenirken (Şekil 4.19), rüzgar hızındaki mevsimsel değişim aralığı dar kalmaktadır (Şekil 4.20).

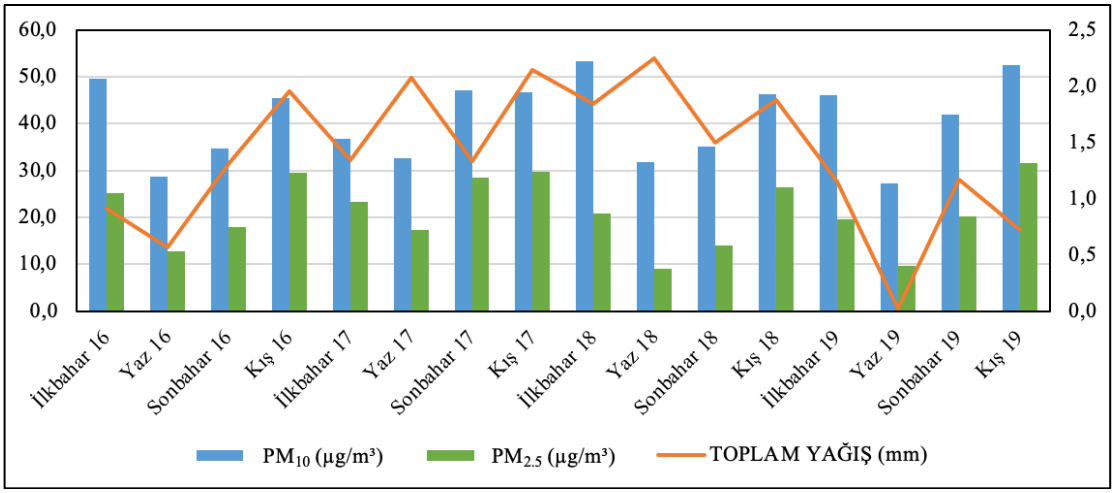
Yaz aylarında düzenli olarak artan sıcaklığa karşın yağış miktarında düzenli bir mevsimsel değişim gözlenmemektedir (Şekil 4.18, Şekil 4.21).



Şekil 4.19: PM_{10}, $PM_{2.5}$ ve ortalama rüzgâr yönü mevsimsel değişim grafiği.



Şekil 4.20: PM_{10}, $PM_{2.5}$ ve rüzgâr hızı mevsimsel değişim grafiği.



Şekil 4.21: PM_{10}, $PM_{2.5}$ ve toplam yağış mevsimsel değişim grafiği.

4.1.3. Çerkezköy Hava Kalitesi Ölçüm İstasyonu Kirletici Konsantrasyonlarının Sınır Değerler ile İncelenmesi

Çalışma kapsamında Çerkezköy hava kalitesi ölçüm istasyonuna ait hava kirletici parametreleri analiz edilerek T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'nın (ÇŞB, 2008) ve Dünya Sağlık Örgütü'nün (DSÖ, 2006) belirlemiş olduğu sınır değerler ile karşılaştırılmış olup Tablo 4.3'te sunulmuştur.

Tablo 4.3: Çerkezköy istasyonu ölçülen PM_{10} konsantrasyonunun sınır değerler ile kıyaslanması.

PM_{10}	**Günlük**							**Yıllık**		
	Ölçüm sayısı	En yüksek değer ($\mu g/m^3$)	ÇŞB sınır değeri ($\mu g/m^3$)	DSÖ sınır değeri ($\mu g/m^3$)	İzin verilen sınır değer aşım sayısı (ÇŞB)	Aşım sayısı (ÇŞB'ye göre)	Aşım sayısı (DSÖ'ye göre)	ÇŞB sınır değeri ($\mu g/m^3$)	DSÖ sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
2016	356	248,3	80	50	35	29	92	52	20	40,7
2017	361	140,5	70	50	35	40	105	48	20	41,6
2018	357	150,0	60	50	35	67	87	44	20	40,8
2019	308	157,8	50	50	35	84	84	40	20	42,0

Tablo 4.3'te sunulan PM_{10} kirliliği verileri incelendiğinde ÇSB'nin belirlemiş olduğu yıllık sınır değerler 2016 yılında 80 $\mu g/m^3$ iken 2019 yılına doğru kademeli olarak her yıl 10 $\mu g/m^3$ azalmış ve 2019 yılında 50 $\mu g/m^3$ olan DSÖ'nün sınır değeri ile aynı seviyeye ulaşmıştır. Yıldan yıla günlük sınır değerin azalmasıyla Çerkezköy istasyonu için günlük sınır değer aşım sayısı 2016 yılında 29 adetten 2017 yılında 40 adete, 2018 yılında 67 adete ve son olarak 2019 yılında 84 adete ulaşmış (sınır değerin %140 üzerinde). Ulusal mevzuata göre günlük sınır değer için izin verilen aşım sayısı çalışma süresince her yıl 35 adettir ve son üç yılda sınır değer aşım gün sayısının limit değerlerin üzerine çıktığı tespit edilmiştir. Öte yandan ilk yıl olan 2016 yılında günlük sınır değer aşmış gün sayısı ulusal mevzuata göre limit değerlerin altında olsa da DSÖ'nün belirlemiş olduğu günlük limit değeri (50 $\mu g/m^3$) 92 gün aştığı görülmektedir.

Yıllık ortalama PM_{10} kirliliği değerleri incelendiğinde çalışma dönemi boyunca çok değişken olmadığı ve 40,7 $\mu g/m^3$ ile 42,0 $\mu g/m^3$ aralığında değişkenlik gösterdiği görülmektedir. Ulusal yıllık sınır değer 2016 yılında 52 $\mu g/m^3$'ten 2019 yılına doğru yıllık 4 $\mu g/m^3$ kademeli azalıp 2019 yılında 40 $\mu g/m^3$ olduğunda Çerkezköy istasyonuna ait yıllık ortalama PM_{10} konsantrasyonu sınır değerin %5 üzerinde kalmaktadır. Ayrıca DSÖ'nün belirlemiş oluğu yıllık ortama sınır değer olan 20 $\mu g/m^3$ değeri ele alınacak olursa, çalışma süresi boyunca her yıl PM_{10} için yıllık ortalama sınır değer aşılmıştır.

Tablo 4.4'te Çerkezköy istasyonuna ait $PM_{2.5}$ kirleticisine ait konsantrasyon ölçüm sonuçları ÇŞB'ye ait ulusal ve DSÖ'nün sınır değerleri ile kıyaslanmıştır. Ulusal mevzuatımızda (ÇŞB, 2008) $PM_{2.5}$ kirleticisine ait günlük sınır değer yer almasa da DSÖ'nün belirlemiş olduğu günlük sınır değer olan 25 $\mu g/m^3$ değeri ele alındığında çalışma dönemi boyunca 2016 yılında 108 gün, 2017 yılında 141 gün, 2018 yılında 77 gün, 2019 yılında 82 gün günlük sınır değer aşılmıştır. DSÖ yıllık ortalama sınır değeri olarak 10 $\mu g/m^3$ olarak belirlemiştir. Çerkezköy istasyonunda 2019 yılında yıllık ortalama kirlilik konsantrasyonu 20 $\mu g/m^3$ olarak ölçülmüş olup AB sınır değerinin altında kalmıştır, fakat 2016 ile 2019 yılları arasında 17,6 ile 25,5 $\mu g/m^3$ aralığında değişen kirlilik konsantrasyonu DSÖ'nün belirlediği 10 $\mu g/m^3$'ün üzerinde yıllık ortalama kirlilik konsantrasyonuna sahip olduğunu göstermektedir.

Tablo 4.4: Çerkezköy istasyonu ölçülen $PM_{2.5}$ konsantrasyonunun sınır değerler ile kıyaslanması.

$PM_{2.5}$	**Günlük**				**Yıllık**		
	Ölçüm sayısı	En yüksek değer ($\mu g/m^3$)	DSÖ sınır değeri ($\mu g/m^3$)	Aşım sayısı (DSÖ'ye göre)	ÇŞB sınır değeri ($\mu g/m^3$)	DSÖ sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
2016	356	74,5	25	108	-	10	22,0
2017	361	89,9	25	141	-	10	25,5
2018	357	100,2	25	77	-	10	17,6
2019	309	93,6	25	82	-	10	20,0

Çerkezköy istasyonunda ölçülen SO_2 kirletici konsantrasyonları sınır değerler ile Tablo 4.5'de kıyaslanmıştır. Günlük sınır değerler 2016 yılında 200 $\mu g/m^3$ olarak belirlenmiş ve her yıl 25 $\mu g/m^3$ azaltılarak 2019 yılında 125 $\mu g/m^3$ olarak belirlenmiştir. Çalışma süresi boyunca günlük limit değerler aşılmamıştır. 20 $\mu g/m^3$ olarak belirlenen yıllık ortalama sınır değer çalışma süresi boyunca her yıl aynı kalmıştır ve sadece ilk yıl olan 2016 yılında 24,2 $\mu g/m^3$ olarak ölçülen SO_2 kirliliği yıllık sınır değerin üzerine çıkmıştır.

Tablo 4.5: Çerkezköy istasyonu ölçülen SO_2 konsantrasyonunun sınır değerler ile kıyaslanması.

SO_2	**Günlük**					**Yıllık**	
	Ölçüm sayısı	En yüksek değer ($\mu g/m^3$)	ÇŞB sınır değeri ($\mu g/m^3$)	İzin verilen sınır değer aşım sayısı	Aşım sayısı (ÇŞB'ye göre)	ÇŞB sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
2016	356	155,6	200	3	0	20	24,2
2017	361	142,1	175	3	0	20	18,3
2018	357	106,6	150	3	0	20	12,8
2019	309	118,8	125	3	0	20	19,5

Tablo 4.6'da NO_x kirleticisinin Çerkezköy istasyonunda ölçülen değerleri ulusal sınır değerler ile karşılaştırılmıştır. ÇŞB'nin belirlemiş olduğu yıllık sınır değer çalışma dönemince 30 $\mu g/m^3$ olarak belirlenmiştir. NO_x kirleticisi için yıllık ortama değer en düşük 2018 yılında 38,5 $\mu g/m^3$ ve en yüksek değer 2019 yılında 53,6 $\mu g/m^3$ olarak ölçülmüştür. Sonuç olarak dört yıl boyunca NO_x için ölçülen yıllık ortalama değer sınır değerin üzerinde olmuştur.

Tablo 4.6: Çerkezköy istasyonu ölçülen NO_x konsantrasyonunun sınır değerler ile kıyaslanması.

NO_x	**Günlük**	**Yıllık**	
	Ölçüm sayısı	ÇŞB sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
2016	356	30	42,4
2017	361	30	43,9
2018	357	30	38,5
2019	309	30	53,6

Çerkezköy istasyonu için NO_2 kirleticisine ait konsantrasyon değerleri Tablo 4.7'de sınır değerler ile kıyaslanmıştır. Çalışma dönemi süresince ulusal yıllık sınır değer 40 $\mu g/m^3$ olarak belirlenmiştir. Ölçüm sonuçlarına göre yıllık ortalama konsantrasyonlar 21,9 ile 27,2 $\mu g/m^3$ aralığında değişiklik göstermektedir ve bu değerler yıllık limit değerlerin altında kalmaktadır.

Tablo 4.7: Çerkezköy istasyonu ölçülen NO_2 konsantrasyonunun sınır değerler ile kıyaslanması.

NO_2	**Günlük**	**Yıllık**	
	Ölçüm sayısı	ÇŞB sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
2016	356	40	24,0
2017	361	40	24,7
2018	357	40	21,9
2019	309	40	27,2

4.1.4. Ölçüm İstasyonları Karşılaştırması

Çerkezköy hava kalitesi ölçüm istasyonu konumu gereği ısınma, ulaşım ve sanayi kaynaklı kirliliğe maruz kalabilen bir noktada yer almaktadır. Ülkemizde Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından yerleştirilen hava kalitesi takibi için kullanılan ölçüm istasyonları içinden Çerkezköy ölçüm istasyonuna benzer konumda yer alan üç farklı ölçüm istasyonu ile şehirden, ulaşımdan, sanayiden uzak konumda bulunan bir ölçüm istasyonu ele alınarak Çerkezköy ölçüm istasyonu ile karşılaştırılma yapılmıştır. Yapılan karşılaştırma ile kirlilik yükleri, yıllık kirletici konsantrasyonu değişimi ve ilişkileri incelenmiştir.

Tablo 4.8'de sunulan Kocaeli Dilovası istasyonunun PM_{10} konsantrasyon ölçüm sonuçlarını ve sınır değerler ile kıyaslanmasını incelediğimizde yıllık ortalama konsantrasyon değerinin 2016 ve 2017 yıllarında 55 $\mu g/m^3$ mertebesinde olduğu ve ilerleyen yıllarda azaldığı görülmektedir. Yıllık ortalama değerler Çerkezköy istasyonuna göre yaklaşık %35 kadar daha yüksek ölçülmektedir. Kocaeli istasyonunda Çerkezköy istasyonuna kıyasla yüksek seyreden günlük aşım sınır değer gün sayısı 2019 yılında Çerkezköy istasyonuna göre azalış gösterse de bu durum ölçüm gün sayısının önceki yıllara göre yaklaşık yarısına düşmesinden kaynaklı olabilmekle beraber, yine de yıllık müsaade edilen aşım gün sayısının üzerine çıkmaktadır. Genel olarak incelendiğinde Çerkezköy istasyonunda kirlilik yükü yaklaşık aynı seviyede seyrederken Kocaeli'nde bu durum daha yüksek kirlilik yüküne rağmen azalış eğilimindedir.

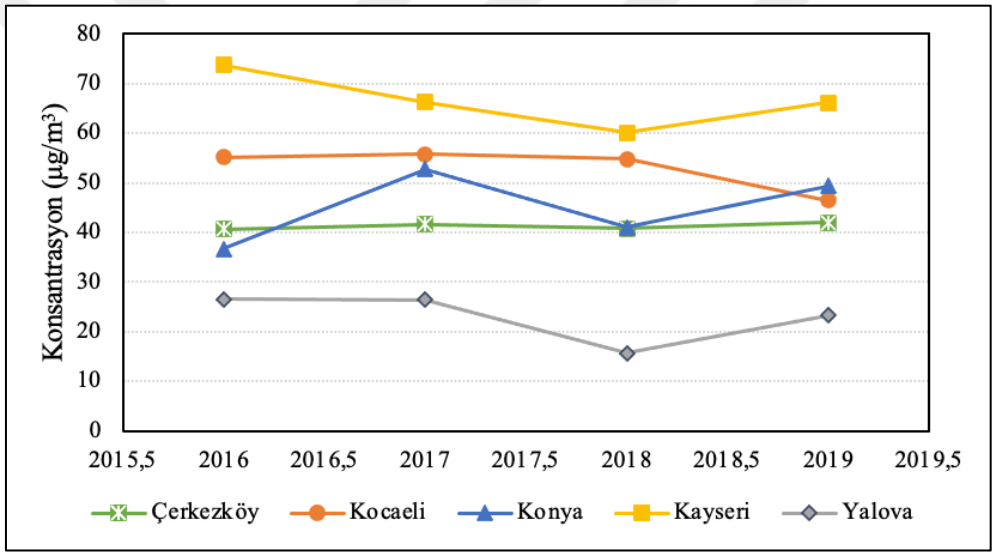
Tablo 4.8: Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB ve Yalova Armutlu istasyonlarında ölçülen PM_{10} konsantrasyonlarının sınır değerler ile kıyaslanması.

PM_{10}		**Günlük**							**Yıllık**		
		Ölçüm sayısı	En yüksek değer ($\mu g/m^3$)	ÇŞB sınır değeri ($\mu g/m^3$)	DSÖ sınır değeri ($\mu g/m^3$)	İzin verilen sınır değer aşım sayısı (ÇŞB)	Aşım sayısı (ÇŞB'ye göre)	Aşım sayısı (DSÖ'ye göre)	ÇŞB sınır değeri ($\mu g/m^3$)	DSÖ sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
Kocaeli	2016	362	386,6	80	50	35	71	147	52	20	55,2
	2017	325	218,2	70	50	35	84	143	48	20	55,8
	2018	353	166,8	60	50	35	108	162	44	20	54,8
	2019	193	139,1	50	50	35	68	68	40	20	46,5
Konya	2016	161	202,8	80	50	35	13	35	52	20	36,7
	2017	234	240,9	70	50	35	50	86	48	20	52,8
	2018	331	242,4	60	50	35	57	84	44	20	41,0
	2019	110	145,5	50	50	35	43	43	40	20	49,4
Kayseri	2016	366	263,0	80	50	35	125	237	52	20	73,7
	2017	354	397,1	70	50	35	126	193	48	20	66,3
	2018	359	308,3	60	50	35	151	195	44	20	60,1
	2019	356	432,7	50	50	35	165	165	40	20	66,1
Yalova	2016	332	332,6	80	50	35	3	12	52	20	26,6
	2017	351	72,6	70	50	35	1	21	48	20	26,4
	2018	351	60,0	60	50	35	1	4	44	20	15,7
	2019	358	84,7	50	50	35	24	24	40	20	23,3

Konya Selçuklu ilçesinde yer alan ölçüm istasyonunda ölçülen PM_{10} konsantrasyonu verileri ile Çerkezköy istasyonu verileri karşılaştırıldığında iki istasyonun PM_{10} kirleticisine ait ölçüm sonuçlarının birbirine yakın olduğunu görülmektedir. Günlük sınır değer aşım sayısı her iki istasyonda da 2016 yılı hariç diğer üç yılda 35 adet/yıl olan sınırı aşmıştır. Yıllık ortalama PM_{10} konsantrasyon değeri 2017 ve 2019 yıllarında yıllık sınır değerin üzerine çıkmıştır.

Çerkezköy istasyonuna benzer şekilde şehirleşmenin kenarında ve sanayinin başlangıcında konumlandırılan Kayseri OSB istasyonunda ölçülen PM_{10} konsantrasyonları Çerkezköy istasyonuna göre belirgin düzeyde yüksek ölçülmüştür. Çalışma süresince her yıl, günlük sınır değer aşım sayısı olan 35 gün en az %257 daha fazla aşılmıştır. Çerkezköy istasyonunda bu sınırın en fazla aşıldığı yılda bu oran %140 oranındaydı. Tablo 4.8'da sunulan yıllık ortalama PM_{10} kirliliği sonuçları 2016-2019 yılları arasında Çerkezköy istasyonunda olduğu gibi limit değerin üzerinde ölçülmüş fakat Çerkezköy istasyonuna göre en az %50 daha yüksektir.

Çerkezköy, Kocaeli, Konya ölçüm istasyonlarının yanında Kayseri istasyonu PM_{10} kirliliğin en yüksek konsantrasyonda ve sıklıkta ölçüldüğü istasyon olurken, Konya ve Çerkezköy istasyonları birbirine yakın kirletici konsantrasyonuna sahip olduğu görülmektedir (Şekil 4.22).



Şekil 4.22: PM_{10} konsantrasyonu yıllık değişimi.

Yalova Armutlu ölçüm istasyonu, Çerkezköy ölçüm istasyonu dahil diğer karşılaştırılan istasyonlar arasında, PM_{10} kirliliği açısından en az kirliliğe sahip ölçüm istasyonudur. ÇSB'nin izin verdiği yıllık aşım gün sayısı sadece 2019 yılında 24 olarak ölçülmüştür, diğer yıllarda yok denecek kadar az seviyelerde olduğu tespit edilmiştir (2016:3, 2017:1, 2018:1) (ÇŞB, 2008). DSÖ'nün belirlemiş olduğu günlük sınır değer olan 50 µg/m^3 en fazla 24 adet ile 2019 yılında ölçülmüştür, bu değer karşılaştırmaya katılan ölçüm istasyonları arasındaki en düşük değerdir (DSÖ, 2006). Yıllık ortalama konsantrasyon değeri Çerkezköy istasyonuna göre 2016 yılında %35 daha düşükken bu oran 2018 yılında %62'ye ulaşmıştır.

Çerkezköy istasyonu haricinde karşılaştırma yaptığımız istasyonlar arasında sadece Yalova Armutlu istasyonunda ve Kayseri OSB istasyonunda 2019 yılında ölçümü yapılan $PM_{2.5}$ kirleticisine ait veriler Tablo 4.9'da sunulmuştur. Ölçüm verileri incelendiğinde DSÖ'nün belirlemiş olduğu günlük 25 $\mu g/m^3$ sınır değer sadece 2019 yılı verisine sahip olan Kayseri OSB istasyonunda ve 2016-2019 yılları arasındaki her yıl Yalova Armutlu istasyonunda da aşıldığı görülmektedir. 2019 yılında günlük ölçüm sayısının 174 olduğu Kayseri OSB istasyonunda günlük ölçüm sayısı 309 olan Çerkezköy istasyonuna kıyasla günlük sınır değer aşım sayısı yaklaşık aynı görünmektedir. Lakin Kayseri OSB istasyonunda ölçüm yapılan yıl olan 2019 yılı verileri kıyaslandığında yıllık ortama değer 33,9 $\mu g/m^3$ ile AB limit değeri olan 25 $\mu g/m^3$'ün üzerinde ve Çerkezköy istasyonuna göre %70 daha fazladır. Çerkezköy ölçüm istasyonundaki yıllık ortama değer Yalova Armutlu ölçüm istasyonuna göre 2016 yılında %37 daha fazladır ve bu oran her yıl kademeli olarak azalarak 2019 yılında %28 oranına düşmüştür.

Tablo 4.9: Kayseri OSB ve Yalova Armutlu istasyonlarında ölçülen $PM_{2.5}$ konsantrasyonunun sınır değerler ile kıyaslanması.

	$PM_{2.5}$	Günlük				Yıllık		
		Ölçüm sayısı	En yüksek değer ($\mu g/m^3$)	DSÖ sınır değeri ($\mu g/m^3$)	Aşım sayısı (DSÖ'ye göre)	ÇŞB sınır değeri ($\mu g/m^3$)	DSÖ sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
Kayseri	2016	-	-	25	-	-	10	-
	2017	-	-	25	-	-	10	-
	2018	-	-	25	-	-	10	-
	2019	174	177,3	25	81	-	10	33,9
Yalova	2016	290	77,3	25	32	-	10	16,1
	2017	264	39,0	25	59	-	10	19,2
	2018	315	43,0	25	31	-	10	13,5
	2019	357	54,5	25	33	-	10	15,6

Tablo 4.10'da SO_2 kirliliği sınır değerler ile kıyaslanmış olup çalışma kapsamında ele alınan beş istasyonda da günlük sınır değer aşımı yaşanmamaktadır. Yıllık ortalama SO_2 konsantrasyonu 2016 yılında 24,2 $\mu g/m^3$ ile Çerkezköy istasyonunda ve 2017 yılında 21 $\mu g/m^3$ ile Kocaeli istasyonunda sınır değer olan 20 $\mu g/m^3$'ü aşmıştır.

SO_2 kirliliği açısından Konya Selçuklu ile Yalova Armutlu istasyonları diğer ölçüm istasyonlarına göre en düşük yıllık ortalama konsantrasyonlara sahiptir ve yıllık sınır değerin üzerine çıkmamışlardır. SO_2 kirliliğine neden olan en önemli kaynak fosil yakıtların yakılması, yani ısınmadır. Konutların içinde konumlandırılan Konya Selçuklu istasyonunda saptanan en

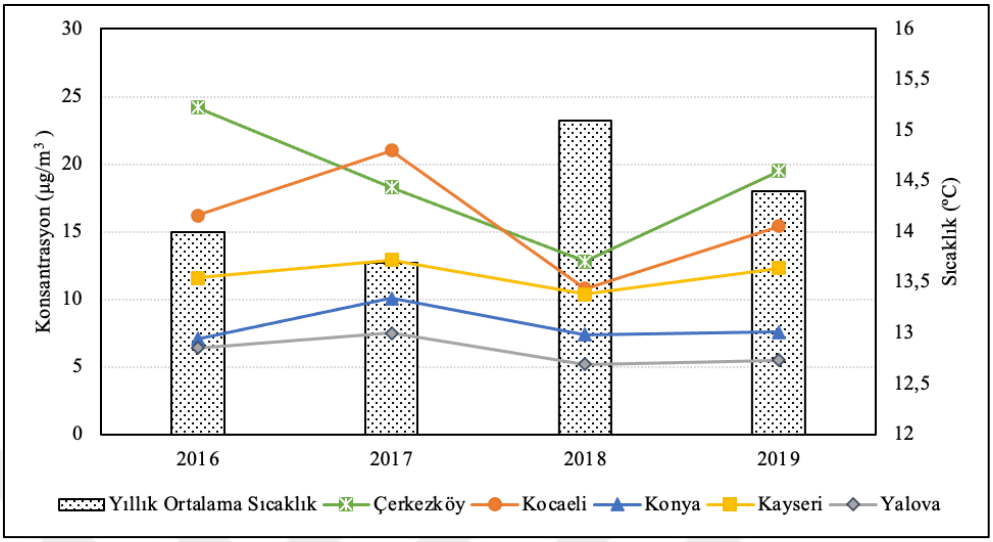
düşük yıllık ortalamalar özellikle ısınma amaçlı fosil yakıtların diğer istasyonların konumlandırıldığı bölgelere göre daha az kullanıldığını göstermektedir. Yalova Armutlu ölçüm istasyonunda ölçülen yıllık ortalama konsantrasyonlar Konya Selçuklu ölçüm istasyonunda ölçülen değerlere göre 2016 yılında %10 daha düşüktür, 2018 yılında ise düşüş farkı %30'a kadar yükselmiştir. Çerkezköy istasyonu ile Yalova Armutlu istasyonu verileri kıyaslandığında 2016 yılında Yalova Armutlu'ya göre Çerkezköy istasyonu ölçüm sonucu %278 daha fazladır. 2017 yılında ise bu oran en düşük olarak %144'e düşmektedir. Bu farkın oluşmasının en büyük nedenleri Yalova Armutlu ölçüm istasyonunun şehirleşmeden uzak, sanayinin var olmadığı konumda yer alması, araç trafiğinden etkilenmemesi ve denize yakın bir noktada var olması olarak söylenebilir.

Tablo 4.10: Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB, Yalova Armutlu istasyonlarında ölçülen SO_2 konsantrasyonlarının sınır değerler ile kıyaslanması.

SO_2		**Günlük**					**Yıllık**	
		Ölçüm sayısı	En yüksek değer ($\mu g/m^3$)	ÇŞB sınır değeri ($\mu g/m^3$)	İzin verilen sınır değer aşım sayısı	Aşım sayısı (ÇŞB'ye göre)	ÇŞB sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
Kocaeli	2016	358	143,5	200	3	0	20	16,2
	2017	358	139,0	175	3	0	20	21,0
	2018	362	52,8	150	3	0	20	10,8
	2019	337	65,4	125	3	0	20	15,4
Konya	2016	170	31,1	200	3	0	20	7,1
	2017	226	72,4	175	3	0	20	10,1
	2018	338	43,1	150	3	0	20	7,4
	2019	323	27,7	125	3	0	20	7,6
Kayseri	2016	356	38,8	200	3	0	20	11,6
	2017	350	64,7	175	3	0	20	12,9
	2018	348	54,8	150	3	0	20	10,4
	2019	338	81,7	125	3	0	20	12,3
Yalova	2016	347	28,9	200	3	0	20	6,4
	2017	360	27,6	175	3	0	20	7,5
	2018	358	29,7	150	3	0	20	5,2
	2019	354	19,6	125	3	0	20	5,5

SO_2 kirletici konsantrasyonları değişim grafiği incelendiğinde (Şekil 4.23) Çerkezköy istasyonuna ait 2016-2017 yılları arası değişimi hariç diğer istasyonlarda ölçülen yıllık değişim tüm yıllarda benzer yönde yükselme ve alçalma grafiği içindedir. Türkiye için yıllık ortalama sıcaklık verileri ile SO_2 kirletici konsantrasyonları karşılaştırıldığında yıllık ortalama sıcaklık

ile yıllık ortalama SO_2 konsantrasyonun ters orantılı olduğunu görülmektedir. (MGM, 2020b) Bu sonuç SO_2 kirliliği ile ısınma kaynaklı kirliliğin ilişkisini de göstermektedir.



Şekil 4.23: SO_2 konsantrasyonu yıllık değişimi.

2016 yılından 2019 yılına gidildikçe yıllık ortalama NO_x konsantrasyonu Kocaeli Dilovası'nda düşüş eğilimindedir (Tablo 4.11). Sadece 2018 yılında yıllık sınır değer altında kalan NO_x konsantrasyon 2019 yılında da 30,1 µg/m^3 ile 30 µg/m^3 olan yıllık sınır değeri %0,3 oranında aşmıştır. Çerkezköy istasyonu ile kıyasladığımızda Kocaeli istasyonunda 2016 yılında %35 daha fazla olan NO_x konsantrasyonu 2019 yılında %43 daha düşük ölçülmüştür.

SO_2 kirliği açısından Yalova Armutlu ölçüm istasyonunun ardından en düşük yıllık ortalamalara sahip olan Konya Selçuklu istasyonu NO_x kirliliği açısından diğer ölçüm istasyonları arasında en yüksek değerlere sahip olarak çalışma dönemi olan 2016-2019 yılları arasında Çerkezköy istasyonu gibi yıllık sınır değerin üzerine çıkmış olsa da Çerkezköy istasyonuna göre yaklaşık %100 daha yüksek yıllık konsantrasyon ortalamasına sahiptir.

Araç trafiğinden oldukça uzak konumda yer alan Yalova Armutlu ölçüm istasyonu, karşılaştırılan istasyonlar arasında en düşük yıllık NO_x konsantrasyonuna sahip ölçüm istasyonudur. Yıllık limit değerlerin yarı değerini aşmayan yıllık değerlere sahiptir. Çerkezköy istasyonu değerleri 2017 yılında %220 oranında Yalova Armutlu istasyonundan daha yüksek değere sahipken bu oran 2019 yılında %255'e ulaşmıştır.

Kayseri OSB ölçüm istasyonunda $PM_{2.5}$ konsantrasyonu ölçümü 2019 yılında başladığı gibi NO_x ve NO_2 konsantrasyonları da 2019 yılında ölçülmeye başlanmıştır.

Tablo 4.11: Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB ve Yalova Armutlu istasyonlarında ölçülen NO_x konsantrasyonlarının sınır değerler ile kıyaslanması.

NO_x		Günlük	Yıllık	
		Ölçüm sayısı	ÇŞB sınır değeri (µg/m^3)	Ortalama değer (µg/m^3)
Kocaeli	2016	349	30	57,3
	2017	349	30	41,7
	2018	353	30	29,6
	2019	307	30	30,1
Konya	2016	182	30	75,1
	2017	245	30	107,5
	2018	290	30	625,6
	2019	256	30	92,1
Kayseri	2016	-	30	-
	2017	-	30	-
	2018	-	30	-
	2019	79	30	25,5
Yalova	2016	346	30	12,3
	2017	358	30	13,7
	2018	337	30	10,9
	2019	338	30	15,1

Çerkezköy istasyonunda çalışma süresince yıllık NO_2 sınır değeri aşılmamış ve genel olarak %40 oranında sınır değerin altında yıllık ortalama sahip olduğu görülmüştür. Tablo 4.12'de verilen Kocaeli Dilovası verilerinde ise sadece 2016 yılında 40,5 µg/m^3 değerindeki yıllık ortama değer ile 40 µg/m^3'lük ulusal sınır değer aşılmış ve diğer yıllarda Çerkezköy istasyonuna yakın ve sınır değerin altında ölçümler gerçekleşmiştir. Ayrıca çalışma kapsamında ele aldığımız diğer istasyonlar arasında Kocaeli Dilovası istasyonunun yanı sıra Konya Selçuklu istasyonunda 2016-2019 yılları arasında NO_2 kirliliğine ait yıllık sınır değer aşımı görülmektedir.

NO_x konsantrasyonlarında olduğu gibi NO_2 konsantrasyon değerleri de sınır değerlerin üzerinde olan Konya Selçuklu istasyonunda yıllık 40 µg/m^3 sınır değerin en az %23 üzerinde kirletici konsantrasyonu tespit edilmiştir. Diğer istasyonlar arasında en yüksek yıllık ortama değerlere sahip olan Konya istasyonunda en yüksek değer 2018 yılında yıllık sınır değerin %102 fazlası olarak ölçülmüştür.

Kayseri OSB ölçüm istasyonunda sadece 2019 yılında ölçümü yapılan NO_x ve NO_2 konsantrasyonları yıllık ulusal sınır değerlerin altında kalmıştır. 2019 yılında NO_x yıllık ortalama konsantrasyonu Çerkezköy istasyonuna göre %52 daha düşüktür, NO_2

konsantrasyonu ise %20 daha düşük ölçülmüştür. Fakat söz konusu istasyonda yıllık sadece 79 ölçüm verisi var olduğundan elde edilen veriler tüm yılın ortalamasını sağlıklı yansıtmadığı düşünülmektedir.

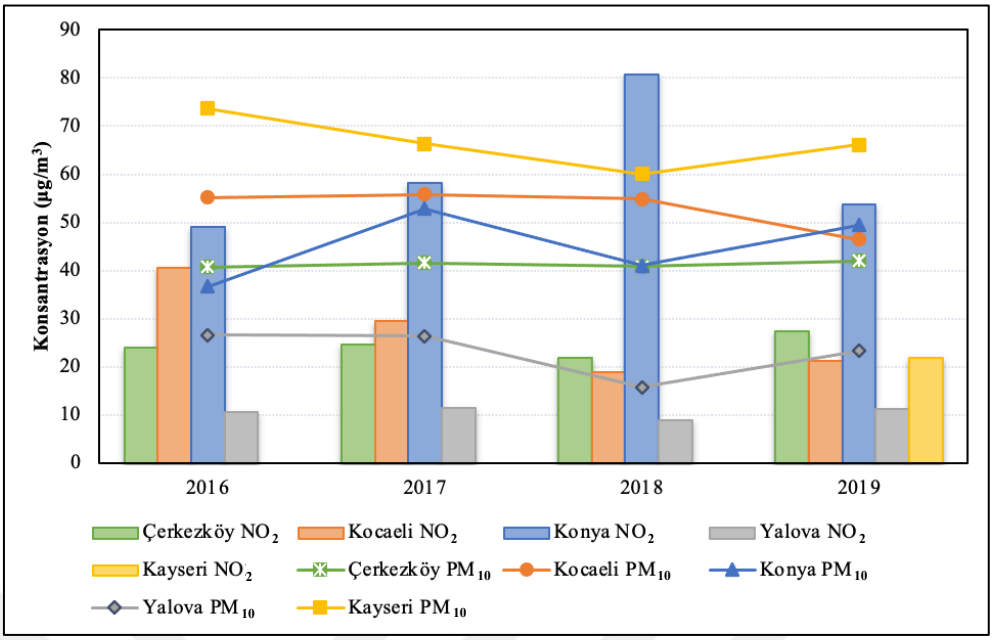
Tablo 4.12: Kocaeli Dilovası, Konya Selçuklu, Kayseri OSB ve Yalova Armutlu istasyonlarında ölçülen NO_2 konsantrasyonlarının sınır değerler ile kıyaslanması.

NO_2		Günlük	Yıllık	
		Ölçüm sayısı	ÇŞB sınır değeri ($\mu g/m^3$)	Ortalama değer ($\mu g/m^3$)
Kocaeli	2016	249	40	40,5
	2017	349	40	29,4
	2018	353	40	18,8
	2019	364	40	21,3
Konya	2016	201	40	49,1
	2017	244	40	58,2
	2018	215	40	80,8
	2019	256	40	53,8
Kayseri	2016	-	40	-
	2017	-	40	-
	2018	-	40	-
	2019	79	40	21,8
Yalova	2016	345	40	10,5
	2017	360	40	11,5
	2018	360	40	8,8
	2019	342	40	11,2

Ölçüm istasyonları arasında en düşük yıllık konsantrasyon değerleri 2016-2019 yılları arasında Yalova Armutlu istasyonunda ölçülmüştür. Yalova Armutlu istasyonuna göre Çerkezköy istasyonu yıllık olarak %115 ile %149 aralığında değişen oranda daha yüksek NO_2 ölçüm değerlerine sahiptir.

Ölçüm sonuçları gösteriyor ki NO_x ile NO_2 kirliliği birbiri ile ilişkilidir. Beklenen bir sonuç olan bu durum ulaşımdan kullanılan içten yanmalı motora sahip araçlardan ve endüstriyel faaliyetlerden salınan yanma yan ürünü olan kirleticilerin atmosfere salınımından kaynaklanmaktadır.

PM_{10} ve NO_2 konsantrasyonlarının karşılaştırılması Şekil 4.24'de yapılmıştır. NO_x ve NO_2'nin birbiri ile olan ilişkisi PM_{10} konsantrasyonu ile de görülmektedir. Bu sonuç bize PM_{10} kirliliğinin ulaşım kaynaklı etkisinin olduğu çıkarımını yaptırmaktadır.



Şekil 4.24: Yılık NO_2 ve PM_{10} konsantrasyonu yıllık değişimi.

4.1.5. Hava Kalitesi İndeksi Değişimi

2016-2019 yılları arasında yaptığımız çalışma kapsamında US EPA standartları ölçeğinde günlük HKİ değerleri yıllara göre sırasıyla Tablo 4.13, Tablo 4.14, Tablo 4.15 ve Tablo 4.16'da sunulmuştur. Buna göre "Kötü" sınıfına giren gün sayısı 1 günle sadece 2016 yılı Mart ayında görülmüştür. "Sağlıksız" gün sayısı en fazla alan yıl 7 gün ile 2017, en az olan yıl 1 gün ile 2016'dir. "Hassas" gün sayısı da 60 gün ile an fazla 2016 yılına ait iken en az 36 gün ile 2018 yılına aittir. "Orta" gün sayısı ise 225 gün ile en fazla 2017 yılında, 101 gün ile en az 2018 yılında görülmüştür. Hava kalitesinin "İyi" sınıfında değerlendirilen, dışarıda sağlıklı bir şekilde insanların vakit geçirip spor ve aktivite yapabileceği en temiz havaya sahip yıl ise 189 gün sayısı ile 2018 yılı olurken 70 gün sayısı ile iyi seviye hava kalitesi indeksine en az sahip olan yıl 2017 yılı olmuştur.

Tablo 4.13: 2016 yılı günlük hava kalitesi indeksi değişimi.

		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
2016	Ocak	119			59	97	73	73	91	128	99	83	91	81	60	101	69	42	52	83	81	121	87	82	83	83	48	36	38	142	128	124
	Şubat	107	98	139	127	32	50	68	65	134	139	93	90	99	68	87	126	110	49	54	55	101	125	146	129	55	100	106	50	69		
	Mart	110	125	79	84	65	97	106	122	74	68	77	79	49	50	51	51	61	126	109	52	107	102	66	203	44	54	62	77	132	88	127
	Nisan	106	61	35	40	55	53	72	70	105	100	71	68	99	127	70	75	97	104	135	112	42	57	96	100	55	76	83	95			
	Mayıs	53			42		37	70	55	38	45	59	80	119	93	57	54	40	40	75	74	52	36	53	109	58	44	39	34	75	77	66
	Haziran	61	69	40	84	33	50	39	34	33	35	39	80	80	88	70	57	55			15	29	37	45	25	47	39	38	51	49	50	
	Temmuz	43	45	42	45	36	28	35		14	31	30	27	30	26	27	39	39	44	33	28	27	45	59		33	46	51	66	75	73	84
	Ağustos	77	75	60	51	58	59	57	56	49	49	53	55	28	36	32	38	36	36	34	40	59	80	51	56	43	33	38	53	55	42	58
	Eylül	34	38	42	47	58	74	48	48	63	53	54	50	52	65	61	50	62	87	90	58	56	59	47	38	33	26	33	49	75	117	
	Ekim	69	59	40	51	52	48	73	86	40	46	58	89	57	44	42	43	33	25	41	33	43	62	65	47	42	40	40	32	65	111	63
	Kasım	91	103	114	66	64	114	98	110	122	67	85	65	63	62	54	65	107	102	67	55	54	51	59	50	102	150	149	86	36	41	
	Aralık	62	110	74	94	64	87	111	58	118	116	133	146	68	77	127	65	58	111	103	153	43	47	59	102	81	108	104	84	41	40	34

Tablo 4.14: 2017 yılı günlük hava kalitesi indeksi değişimi.

		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
2017	Ocak	102	137	123	123	82	48	61	117	74	58	47	138	143	106	45	55	45	37	34	51	82	88	57	56	84	62	81				80
	Şubat	89	164	143	113	84	100	77	59	34	52	65	52	54	77	121	97	75	152	119	93	140	110	128	117	98	31	82	94			
	Mart	128	97	116	87	92	137	100	71	72	91	98	74	51	60	100	111	103	102	111	75	139	44	49	48	85	98	56	76	64	64	76
	Nisan	50	42	53	67	76	91	97	87	55	78	59	61	49	84	82	78	90	36	68	85	69	52	73	52	64	71	90	76	119	82	
	Mayıs	51	55	65	71	69	75	84	55	63	50	52	110	116	56	40	54	52	49	36	63	64	53	44	46	58	52	39	36	53	52	100
	Haziran	91	57	63	62	54	39	82	98	45	52	69	47	44	65	69	49		33	30	55	83	89	68	100	40	46	49	49	79	83	
	Temmuz	61	65	55	45	47	45	55	46	65	66	47	48	55	61	35	43	53	56	57	60	67	61	90	71	82	84	71	75	90	77	53
	Ağustos	48	57	69	72	73	79	78	58	49	43	73	57	59	38	41	31	43	55	61	43	50	57	70	61	52	46	55	57	52	50	48
	Eylül					51	59	52	59	49	47	110	101	67	50	53	50	63	89	78	92	70	58	55	84	55	63	49	49	50	49	
	Ekim	59	69	55	58	99	140	102	13	92	81	72	59	81	102	79	96	49	46	60	118	152	139	91	100	58	88	137	119	55	48	69
	Kasım	63	87	156	80	54	79	72	69	73	82	161	118	116	121	92	68	65	75	51	53	57		81	133	107	116	103	86	96	137	
	Aralık	92	82	85	85	55	71	107	154	141	72	98	116	127	134	140	128	84	43	39	64	74	73	70	95	142	163	140	90	85	68	58

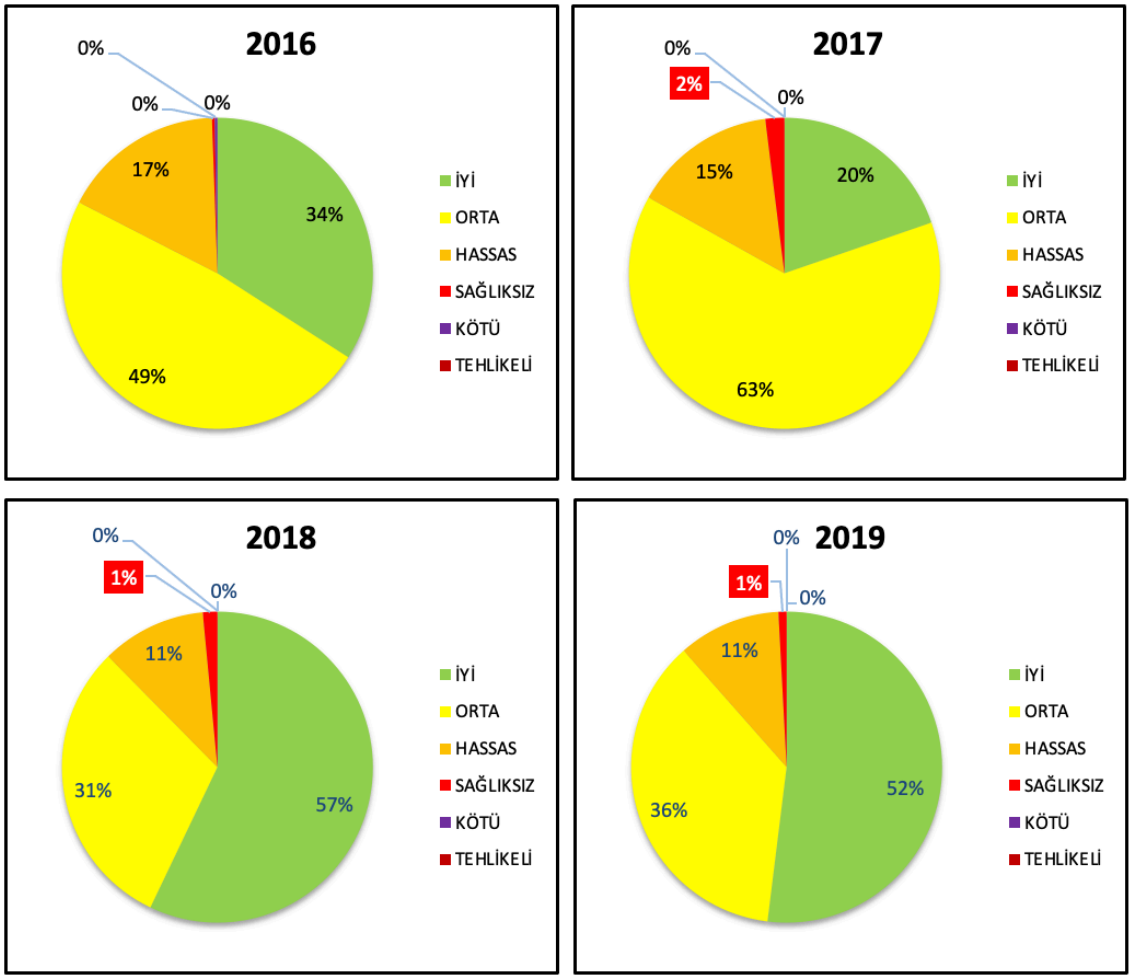
Tablo 4.15: 2018 yılı günlük hava kalitesi indeksi değişimi.

		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
2018	Ocak	90	107	79	71	85	151	117	136	104	54	76	65	36	34	49	101	127	51	90	120	53	48	56	60	52	41	62	64	130	171	
	Şubat	155	137	125	84	64	26	52	111	115	66	35	18	70	76	42	46	57	64	42	36	57	44	19	31	49	46	42	67			
	Mart	77	124	102	83	58	59	112	102	62	126	113	133	91	60	97	124	124	102	25	38	52	39	45	25	45	95	82	40	73	124	141
	Nisan	75	38	46	100	115	83	41	49	60	83	83	126	49	26	52	32	45	47	54	71	40	74	90	74	94	58	54	49	37	34	
	Mayıs	45	46	55	46	44	51	77	48	78	64	31	29	47	76	81	90	84	68	50	26	27	30	25	38	33	46	46	47	34	36	32
	Haziran	40	40	22	54	59	99	60	50	40	31	34	33	28	18	26	28	28	30	32	26	31	81	54	17	15	27	29	36	56	56	
	Temmuz	39	33	33	32	32	37	32	31	36	29	31	26	37	34	28	40	70	39	39	46	39	58	58	34	50	38	34	36	35	34	22
	Ağustos	37	45	45	40	44	41	36	41	21	27	30	25	27	29	37	44	39	39	37	30	31	30	33	44	31	25	27	31	47	45	41
	Eylül	40	56	54	37																											
	Ekim					19	29	22	20	23	24	60	56	37	38	34	32	48	56	56	62	73	114	114	82	90	40	154	151	99	85	90
	Kasım	86	44	27	23	31	41	24	25	24	21	30	36	17	19	36	41	38	13	66	20	39	24	43	42	69	109	105	35	10	18	
	Aralık	48	46	47	54	42	20	45	154	104	58	56	54	141	75	77	63	22	45	43	80	89	108	103	115	41	52			120	77	59

Tablo 4.16: 2019 yılı günlük hava kalitesi indeksi değişimi.

		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
2019	Ocak	30	42	66	32	31	73	54	75	132	50	84	69	54	129	69	82	143	137		80	71	49	96	68	79	67	46	104	85	72	66
	Şubat	68	136	108	116	53	26	37	42	56	97	138	72	28	35	36	45	67	136	84	118	115	143	31	40	43	73	59	67			
	Mart	110	82	38	90	125	83	57	156	109	73	91	73	34	41	49	102	56	121	103	51	42	48	63	48	62	79	50	45	81	37	80
	Nisan	56	62	52	49	51	60	53	82	40	44	93	89	78	30	26	58	105	44	48	57	60	60	38	67	49	37	53	98	90	71	
	Mayıs	49	29	54	60	39	65	49	27	44	59	68	66	39	45	75	39	35	58	67	83	64	79	76	31	61	68	36	54	63	67	71
	Haziran	35	51	63	43	41	54	50	45	44	40	44	54	53	49	48		51	45	41	53	50	47	47	49	47	39	40	46	38	38	
	Temmuz	37	38	40	38	42	42	42	59	44	38	38	39	44	39	40	43	41	41	39	44	44	48	45	37	40	38	40	41	45	44	51
	Ağustos	45	43	77	43	44	40	40	36	29	29	34	43	39	42	35	30	27	30	36	39	38	85	47	52	51	55	44	40	39	39	41
	Eylül	39	38	39	40	35	30	33	33	33	30	32	31	37	34	31	29	47	79	31	23	27	24	34	37	23	58	55	26	39	108	
	Ekim	96	44	122	95	29	27	51	55	35	126	72	33	25	44	41	55	39	79	74	60	78	54	133	36	44	64	46	52	51	51	39
	Kasım	23	37	78	98	86	110	113						79	98	123	106	71	71	134	90	61	56	37	41	61	72	58	113	130	87	
	Aralık	50	36	118	42	27	33	116	82	67	114	90	58	67	94	82	92	147	151	119	158	156	144	102	69	41	44	65	67	61	26	33

Hava kalitesi indeksi verilerinin yıllık oranlarını incelediğimizde Şekil 4.25'de sunulan grafiksel dağılımı görmekteyiz. Yıllık dağılım oranlarına göre "İyi" sınıfta yer alan gün sayısı oranı en yüksek yıl %57 oran ile 2018 yılı olmuştur ve bu yılı %52 oran ile 2019 yılı takip etmiştir. "İyi" ve "Orta" sınıfta yer alan gün sayılarını kabul edilebilir kaliteli hava olarak nitelendirirsek en yüksek hava kalitesine sahip yılların %57+%31 ve %52+%36 oranları ile toplam %88 oranına sahip 2018 ve 2019 yıllarında olduğu görülmüştür.



Şekil 4.25: Yıllık hava kalitesi indeks oranları dağılımı.

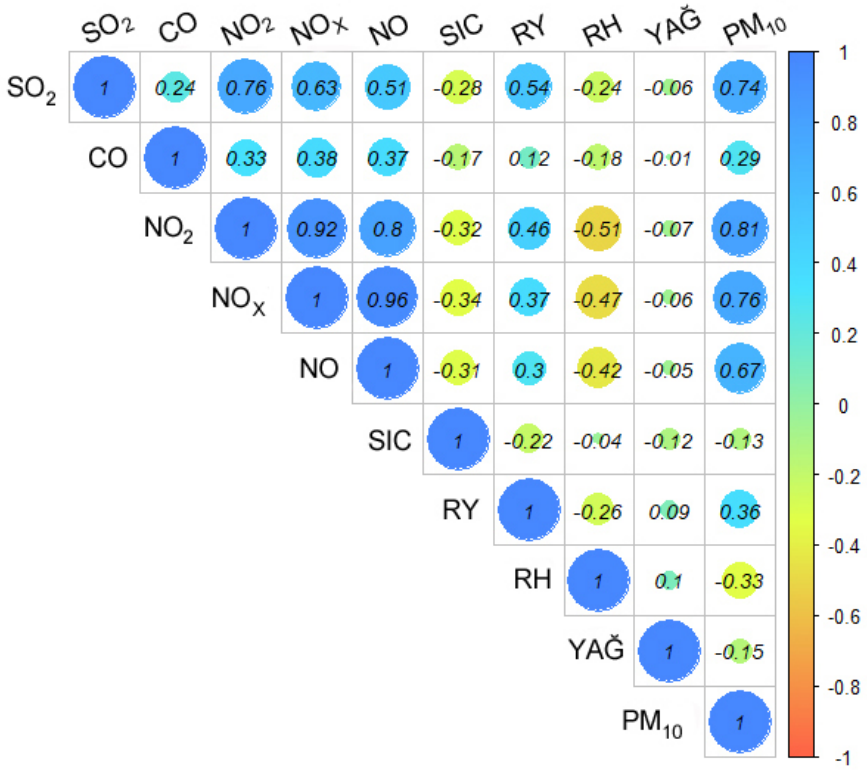
4.2. HAVA KALİTESİNİN EĞİTİLEBİLİR ALGORİTMALARDA MODELLENMESİ

Bu bölümde veri setinde yer alan kirletici parametreler ile meteorolojik parametreler arasındaki korelasyon ilişkileri ve veri frekans dağılımları incelenmiştir. Ardından altı farklı makine öğrenmesi metodu kullanılarak PM değerleri tahmin edilmiş olup gerçek değerlere en yakın tahmin sonucunu veren model tespit edilmiştir.

4.2.1. Kirletici Parametreler ile Meteorolojik Parametreler Arasındaki İlişki

Kirletici ve meteorolojik değişkenler arasındaki ilişkiyi gösteren korelasyon matrisi Şekil 4.26'da verilmiştir. Korelasyon matrisi incelendiğinde PM_{10} değişkeni en yüksek NO_2 ile korelasyon göstermektedir (0,81). NO_2'nin PM_{10} ile bu kadar ilişkili olması beklenen ve bilindik bir durumdur. Çünkü NO_2 partikül madde ile birlikte yanma ürünü olarak ortaya çıkabilmektedir. PM_{10} ile yüksek ilişkili diğer bir değişken ise NO_x (0,76) olup onu sırasıyla SO_2 ve NO takip etmektedir (sırasıyla 0,74 ve 0,67). NO, NO_2 ve NO_x arasındaki korelasyonun

yüksek olmasının sebebi birbiriyle sürekli ilişki durumunda olduğundandır. SO_2'nin de yüksek ilişki göstermesinin sebebi aynı kaynaklı emisyonlardan oluşması olarak görülmektedir; NO, NO_2 ve NO_x kirleticileri yanma prosesinin yan ürünleridir.

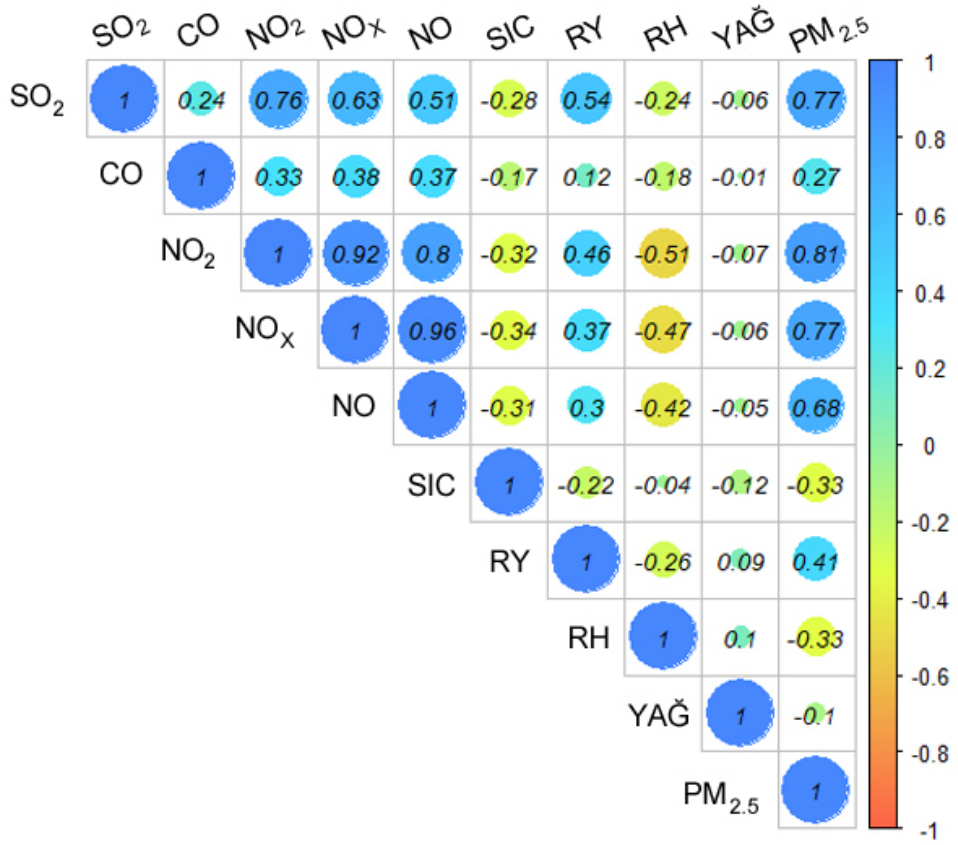


Şekil 4.26: PM_{10} ile kirletici ve meteorolojik parametreler arasındaki ilişki matrisi.

Meteorolojik veriler açısından incelendiğinde ise PM_{10} ile en güçlü ilişki RY (rüzgâr yönü) arasında olduğu görülmektedir (0,36). Rüzgâr yönü ile kirletici taşınımının doğrusal orantıda olduğu, emisyon kaynaklarından çıkan PM_{10} parametresinin belirli bir yönden diğer yönlere oranla daha fazla geldiği durumu ortaya çıkmaktadır. Rüzgâr hızı (RH) ile PM_{10} arasında ise ters bir ilişki görünmektedir (-0,33). Bu beklenen bir durum olup RH'nin artışı kararsız hava şartlarını oluşturduğundan kirletici dağılımını arttırır ve sonucunda kirletici ölçüm değerleri düşmektedir.

RH ile sırasıyla NO_2 (-0,51), NO_x (-0,47) ve NO (-0,42) değişkenleriyle yüksek oranda ters ilişkilidir, RH artışı ile NO_2, NO_x ve NO parametrelerinde azalış görülmektedir.

PM_{10} ile yağış parametresinin korelasyonu diğer kirleticilere göre nispeten daha fazladır (-0,15). Bu da yağışla partikül maddenin ortamdan daha fazla yok olduğunu, çökerek uzaklaştığını göstermektedir.



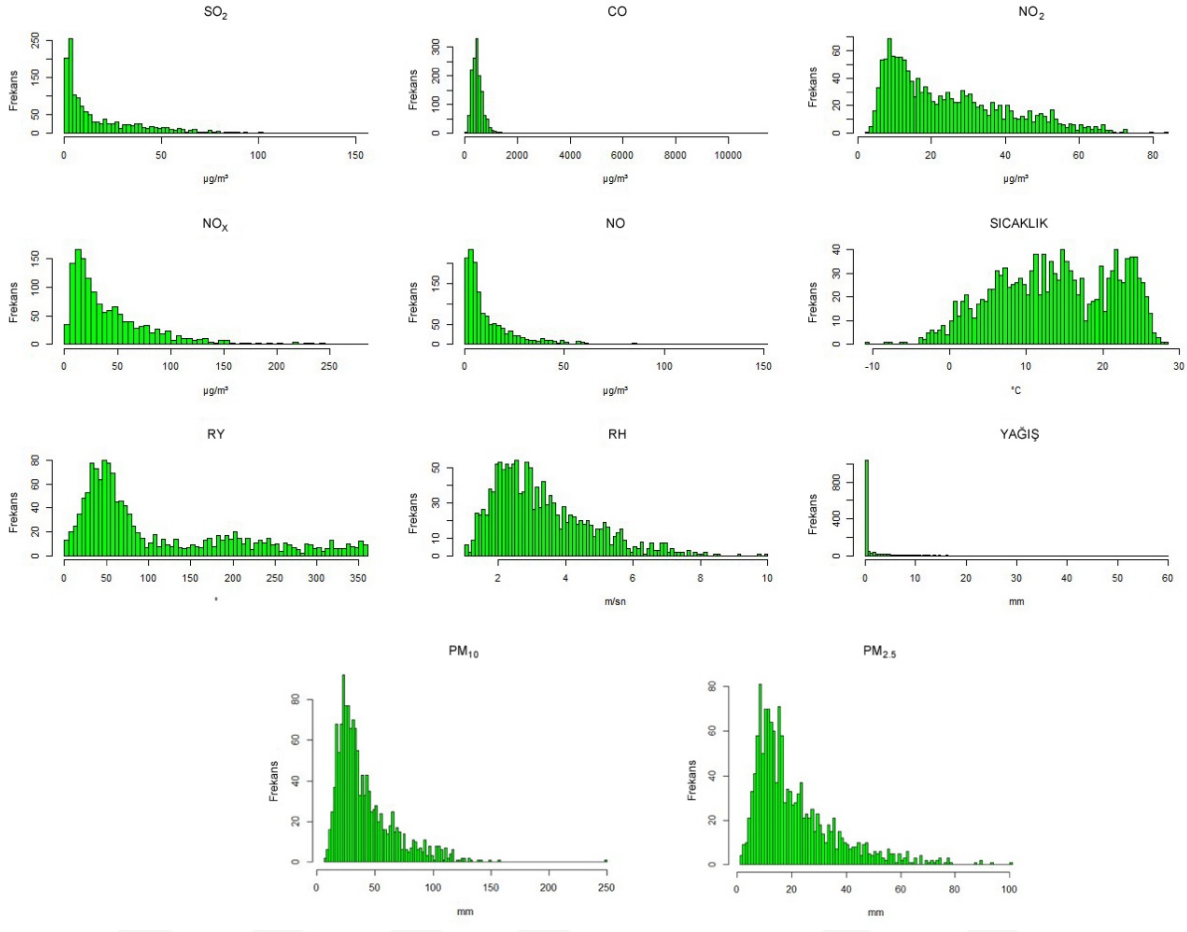
Şekil 4.27: $PM_{2.5}$ ile kirletici ve meteorolojik parametreler arasındaki ilişki matrisi.

$PM_{2.5}$ ile kirletici ve meteorolojik veriler arasındaki ilişki matrisi Şekil 4.27'te sunulmuştur. Şekil 4.27'deki korelasyon matrisi incelendiğinde $PM_{2.5}$ parametresinin diğer parametrelerle PM_{10}'a benzer bir korelasyon içinde olduğu görülmektedir. PM_{10} verilerine kıyasla $PM_{2.5}$ korelasyon değerlerinde en büyük değişim rüzgâr yönü (RY) parametresinde olduğu görülmektedir (0,36'dan 0,41'e). Bu durum taşınımın etkisini ortaya koymaktadır.

PM_{10} ile sıcaklık arasındaki korelasyon değeri -0,13 değerinden $PM_{2.5}$ ile sıcaklık arasındaki ilişkinin -0,33'e yükselmesinde ısınma ve proses kaynaklı fosil yakıt kullanımının etkili olduğu sonucu çıkarılabilir.

4.2.2. Veri Frekansı ve Dağılımı

Veri tabanındaki parametrelerin frekans dağılımları incelenerek genel olarak hangi değerlerde yoğunluk olduğu incelenmiştir. Şekil 4.28'te SO_2, CO, NO_2, NO_x, NO, PM_{10} ve $PM_{2.5}$ kirleticileri ile ve RY, RH, yağış meteorolojik verilerinin histogram grafiği verilmiştir.



Şekil 4.28: Kirletici konsantrasyonu ve meteorolojik veri frekansları.

İnsan sağlığının korunması için 24 saatlik SO_2 sınır değeri 125 µg/m^3'tür. SO_2'ye ait dağılım grafiği incelediğimizde 0-150 µg/m^3 aralığında seyreden verilerde özellikle 0-20 µg/m^3 aralığında sıklık görülmektedir, sınır değere yakın ve üzerindeki gün sayısı oldukça az ölçülmüştür. Ekosistemin korunması için yıllık sınır değer olan 20 µg/m^3 ise sıklıkla aşılmış ve ölçüm frekansı yaklaşık 20 µg/m^3'ten 100 µg/m^3'e kadar doğrusal azalış göstermektedir.

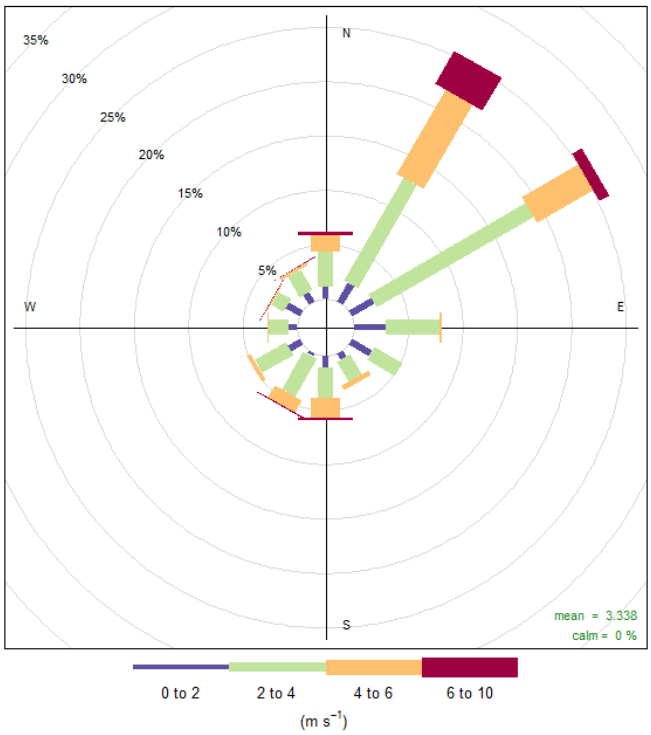
CO emisyon dağılımı 0-2.000 µg/m^3 aralığında pik yaptığı tespit edilmiş olup, sınır değeri olan 10.000 µg/m^3'e kadar görülen ölçüm verilerinde sınır değere yakın veri sayısı yok denecek kadar azdır.

0-20 µg/m^3 aralığında pik yapan günlük NO_2 ölçüm verileri 80 µg/m^3'e kadar lineer dağılım göstermektedir. Yıllık sınır değer olan 40 µg/m^3 değeri sıklıkla aşıldığı, NO_2 kirliliği açısından önem arz eden bir bölge olduğu görülmektedir.

NO_x kirlilik parametresinin yoğunluk dağılımına baktığımızda 0-250 µg/m^3 aralığında seyrettiği görülmüştür. 15 µg/m^3 değerinde en yüksek frekansa ulaşan NO_x, bakımından vejetasyonun korunması için yıllık sınır değer 30 µg/m^3'tür ve bu sınır değer genel olarak aşılmıştır.

Hava sıcaklığının çalışma dönemi boyunca -10-30 °C aralığında seyrettiği, 5-15 °C aralığında ve 20-25 °C aralığında sıklık gösterdiği tespit edilmiştir.

Rüzgâr yönü kirleticilerin kaynaklarının konumlarına göre, ölçülen kirletici konsantrasyonunu değiştirebilecek öneme sahip bir parametredir. Ölçüm istasyonun olduğu bölgeye ait rüzgâr yönü frekansı grafiği Şekil 4.29'da sunulmuştur. Meteoroloji Genel Müdürlüğünün verilerine göre hâkim rüzgâr yönü Poyraz yönünde ölçülmüştür. En güçlü rüzgarlar ise Yıldız-Poyraz yönünde ağırlık göstermektedir. Yılın büyük bir bölümünde Poyraz rüzgarları etkili olurken yılın bazı günlerinde ise Lodos ile Kıble yönlerinden ters rüzgarlar esmektedir.

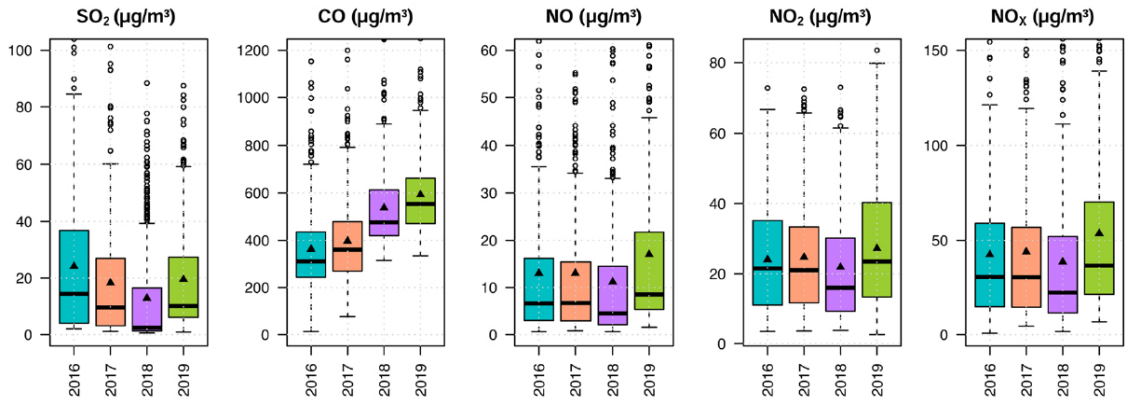


Şekil 4.29: Rüzgâr yönü frekansı (%).

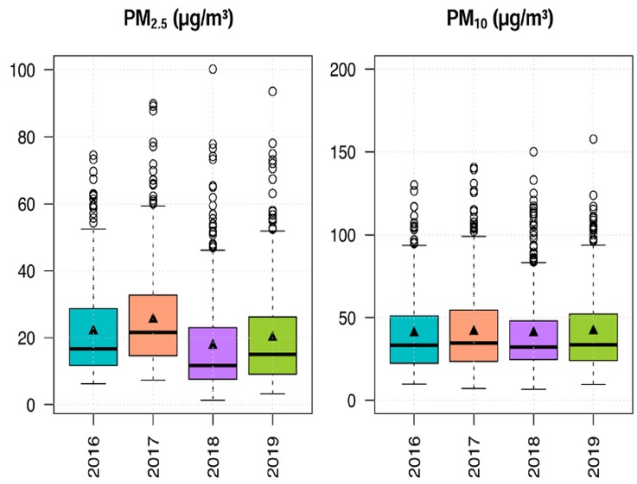
Rüzgâr yönü (RY) 30°-70° aralıklarında yoğunluk göstermektedir. Rüzgâr hızı (RH) da 2-4 m/sn aralığında en fazla frekansa sahiptir.

PM_{10} histogram grafiği incelendiğinde günlük hava kirliliği ölçüm verilerinin sıklığını 30-40 $\mu g/m^3$ aralığında olduğu ve günlük sınır değerin (50 $\mu g/m^3$) birçok defa aşıldığı görülmektedir. Benzer şekilde $PM_{2.5}$ kirlilik dağılımının 0-100 $\mu g/m^3$ aralığında değiştiği, günlük kirlilik sıklığının 0-40 $\mu g/m^3$ aralığında olduğu görülmektedir. Fakat günlük AB sınır değerinin 25 $\mu g/m^3$ olduğu $PM_{2.5}$ kirliliği için ölçümlerin PM_{10} kirliliğine göre daha çok sınır değeri aştığı gözlenmiştir.

Kirletici ve meteorolojik parametrelere ait dört yıllık dağılım kutu grafikler ile açıklanmıştır. SO_2, CO, NO, NO_2 ve NO_x kirleticilerine ait yıllık dağılım grafikleri Şekil 4.30'da, $PM_{2.5}$ ve PM_{10} kirleticilerine ait yıllık dağılım grafikleri Şekil 4.31'de ve meteorolojik veriler olan sıcaklık, rüzgar yönü (RY), rüzgar hızı (RH), yağış verilerine ait yıllık dağılım grafikleri Şekil 4.32'de sunulmuştur.



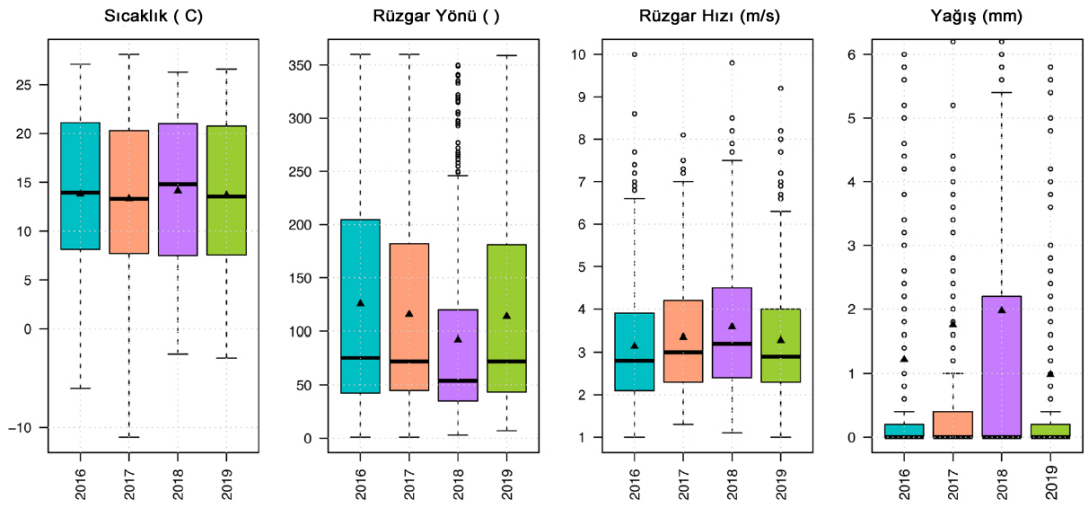
Şekil 4.30: SO_2, CO, NO, NO_2 ve NO_x yıllık dağılım grafikleri.



Şekil 4.31: $PM_{2.5}$ ve PM_{10} yıllık dağılım grafikleri.

Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliğine göre ekosistemin korunması için yıllık SO_2 sınır değeri 20 µg/m^3'tür (ÇŞB, 2008). Şekil 4.30'da yer alan SO_2 kirliliğinin yıllık değişim grafiği incelendiğinde kükürt dioksit bakımından en kirli yıl olan 2016 yılındaki SO_2 kirliliği ortalamasının sınır değerin üzerinde (yıllık ortalama 24,19 µg/m^3) olduğu ve sonraki yıllarda düşme eğiliminde olduğu görülse de (2018 yılı için ortalama 12,84 µg/m^3) 2019 yılında tekrar yükselme eğiliminde olduğu (yıllık ortalama 19,47 µg/m^3) tespit edilmiştir. Ayrıca günlük 125 µg/m^3 limit değerinin de ara ara aşıldığı görülmektedir.

Şekil 4.30'da yer alan NO, NO_x, NO_2 ve SO_2 kirleticileri ile Şekil 4.32'de yer alan rüzgâr yönünün (RY) yıllara göre benzer artış ve azalış gösterdiği dikkat çekmektedir. RY ile kirletici konsantrasyonlarının değişimi kirletici kaynaklarının lokasyonunun önemini ortaya koymaktadır.



Şekil 4.32: Sıcaklık, rüzgâr yönü (RY), rüzgâr hızı (RH), yağış yıllık dağılım grafikleri.

CO kirliliği düşük seviyede seyretmesine rağmen her yıl kararlı bir şekilde yükselme görülmektedir. İnsan sağlığının korunması için yıllık sınır değer olan 10000 µg/m^3 değerine yakın ortalama değer ölçülmemekte ve CO bakımından oldukça temiz bir bölge olduğu söylenebilmektedir.

Birbirleri ile sürekli etkileşim halinde olan NO, NO_2 ve NO_x kirleticilerinin yıllık dağılımları incelendiğinde birbirlerine benzer değişimler göstermektedirler. 2019 yılında artış gösteren NO_2 kirliliği yıllık ortalaması insan sağlığının korunması için belirlenen limit değer olan 40 µg/m^3 değerinin oldukça altında kalmaktadır (yıllık ortalama 27,19 µg/m^3). Fakat 2016 ve 2017 yıllarında ortalama 30 µg/m^3 sınır değeri ile limitlerde ölçülen NO_x kirliliği 2018 yılındaki

azalışın ardından 2019 yılında sınır değeri aşmıştır (yıllık ortalama 53,52 µg/m^3). Rüzgâr hızını (RH) 2019 yılında azalması bu kirliliğin ortamda bulunmasına yardımcı olabileceği düşünülebilir. NO_2, NO_x ve NO bakımından 2019 yılında kirletici konsantrasyonunda artış görülmüştür.

Genel olarak 2018 yılında kirletici parametrelerinde azalış gözlenirken yağış parametresinde diğer yıllara göre artış olması ilişkili gibi görünse de Şekil 4.26 ve Şekil 4.27'de yer alan korelasyon değerlerine bakıldığında ilişki durumunun çok düşük olduğu tespit edilmiştir.

Partikül madde kirliliğinin yıllık dağılım grafikleri incelendiğinde PM_{10}'un yıllar içinde önemli oranda değişim göstermediği, 2016 yılından sonra (yıllık ortalama 40,7 µg/m^3) 2017 yılında bir miktar artış gösterdiği (yıllık ortalama 41,6 µg/m^3) 2018 yılında tekrar az miktarda düştüğü (yıllık ortalama 40,8 µg/m^3) fakat bu değişimlerin yok denecek kadar az olduğu görülmektedir. İnsan sağlığının korunması için sınır değerin 40 µg/m^3 olduğu 2019 yılında PM_{10} konsantrasyonu 42 µg/m^3 ile yıllık sınır değeri aşmıştır. En düşük yıllık PM_{10} kirliliği 2016 yılında tespit edilmiştir (40,7 µg/m^3). ÇŞB'nin belirlemiş olduğu izin verilen sınır değer aşım sayısı (35 gün) 2017, 2018 ve 2019 yıllarında aşılmıştır.

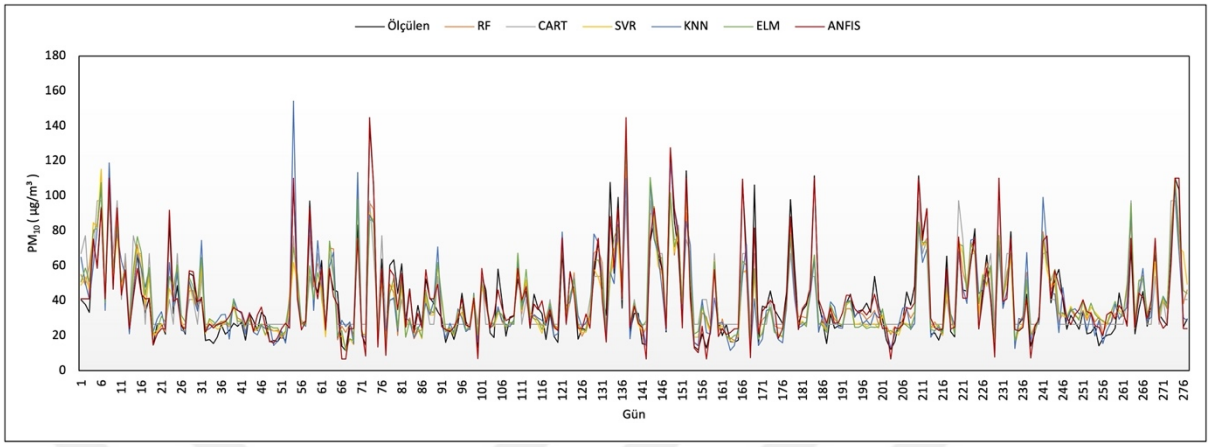
$PM_{2.5}$ kirliliği 2017 yılında en yüksek ortalama değere sahip olduğu görülmüştür (25,50 µg/m^3). AB2008/52 direktifine göre yıllık ortalama limit değerin 25 µg/m^3 olduğu dikkate alındığında $PM_{2.5}$ kirliliği olarak en kirli yıl olan 2017 yılında limit değer aşılmıştır. $PM_{2.5}$ kirliliğinin en az görüldüğü 2018 yılında ortalama yıllık konsantrasyon 17,65 µg/m^3 olarak ölçülmüş ve 2018 yılı en az kirlilik ortalamasına sahip yıl olsa da DSÖ yıllık ortalama sınır değer olan 10 µg/m^3 konsantrasyon değerinin üzerinde olduğu tespit edilmiştir.

4.2.3. Modellerin Tahmin Performanslarının Karşılaştırması

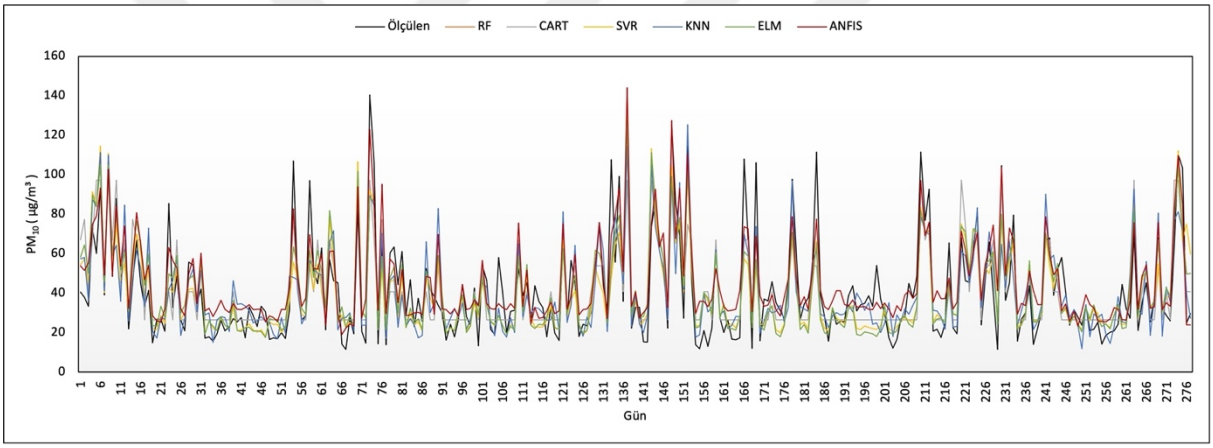
Veri tabanındaki örneklerin %80'i ile model eğitimi yapıldıktan sonra geri kalan %20 örnekleme verileri her modele ayrı ayrı verilerek PM_{10} ve $PM_{2.5}$ için tahminler yapılmıştır. İki farklı kirletici olan PM_{10} ve $PM_{2.5}$ için tahmin yapılırken aynı zamanda bu iki partikül madde için ayrı ayrı kirletici veriler ve meteorolojik veriler, kirletici veriler, meteorolojik veriler olmak üzere üç farklı tahmin ve analiz yapılmıştır.

PM_{10} ve $PM_{2.5}$ kirleticisi için meteorolojik veriler, kirletici veriler, kirletici veriler ve meteorolojik veriler kullanılarak RF, CART, SVR, KNN, ELM, ANFIS modelleri ile yapılan

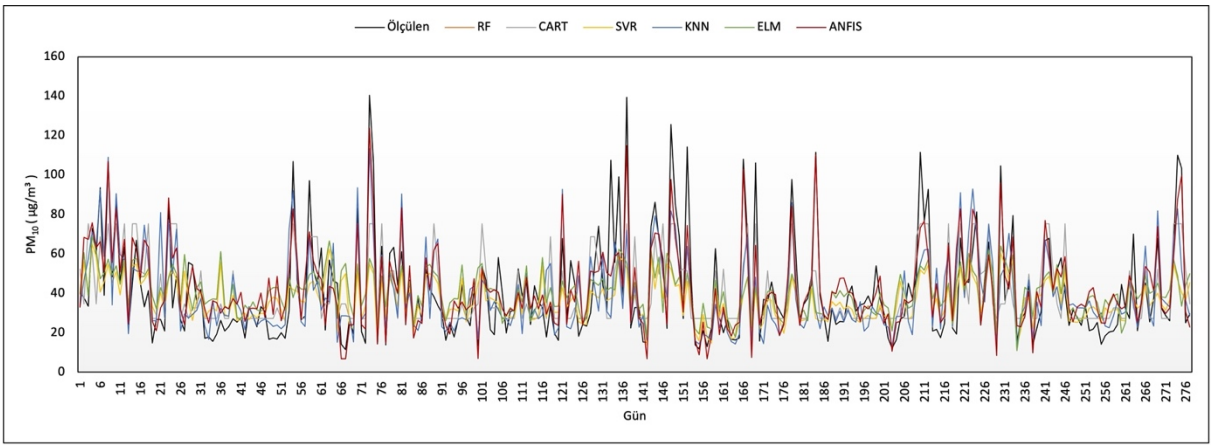
tahmin sonuçları grafiksel olarak Şekil 4.33'ten Şekil 4.38'e kadar olan grafiklerle görselleştirilmiştir.



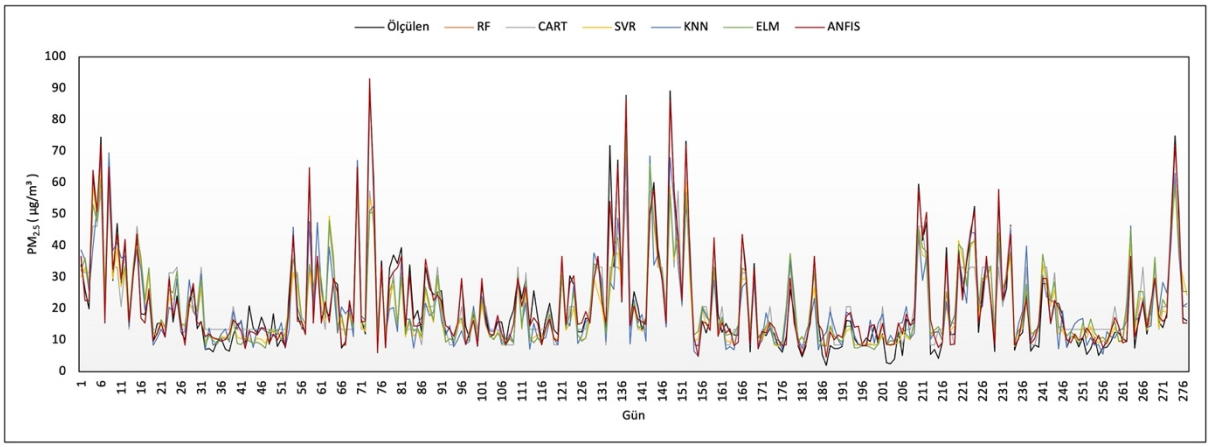
Şekil 4.33: Kirletici ve meteorolojik veriler ile PM_{10} tahmini model çıktıları.



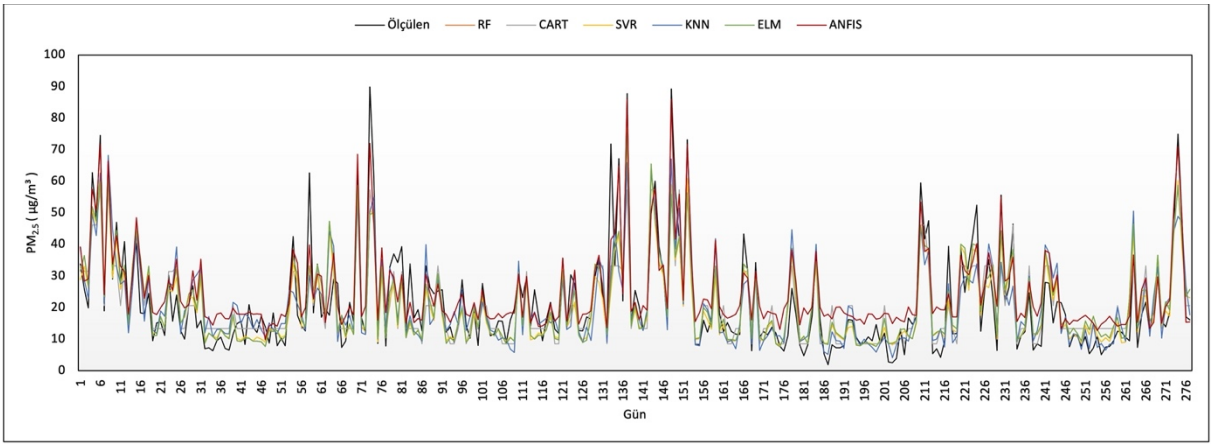
Şekil 4.34: Kirletici veriler ile PM_{10} tahmini model çıktıları.



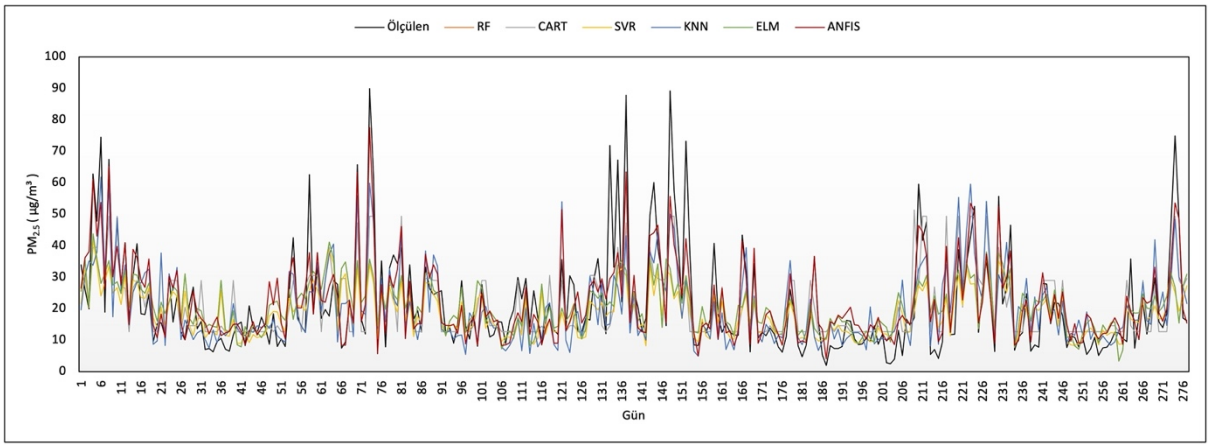
Şekil 4.35: Meteorolojik veriler ile PM_{10} tahmini model çıktıları.



Şekil 4.36: Kirletici ve meteorolojik veriler ile $PM_{2.5}$ tahmini model çıktıları.



Şekil 4.37: Kirletici veriler ile $PM_{2.5}$ tahmini model çıktıları.



Şekil 4.38: Meteorolojik veriler ile $PM_{2.5}$ tahmini model çıktıları.

Hava kalitesi ölçüm istasyonundan alınan günlük ortalama kirletici konsantrasyonları ile meteorolojik veriler makine öğrenmesi metotları olan RF, CART, SVR, KNN, ELM ve ANFIS ile modellenmiş ve PM_{10} ile $PM_{2.5}$ kirliliği tahmin edilmiştir.

Modellerin tahmin performansları korelasyon katsayısı (R), ortalama karesel hatanın karekökü (RMSE) ve ortalama mutlak hata (MAE) istatistik ölçütleri kullanılarak karşılaştırılmıştır. R değerinin yüksek (1'e yakın), RMSE ve MAE değerlerinin ise düşük (0'a yakın) olması arzu edilen bir durumdur. Modellerin tahmin performansının ne kadar başarılı olduğunu bu parametreler yardımı ile karşılaştırabiliriz.

Hem kirleticiler hem de meteorolojik değerler kullanılarak PM konsantrasyonları tahmin edilmiş olup model sonuçları da Tablo 4.17'de verilmiştir. Her metodun tahmin süresi saniye cinsinden tabloda verilmiştir.

Tablo 4.17: Kirletici ve meteorolojik verilerden modellerin PM tahmin performansları.

	PM_{10}				**$PM_{2.5}$**			
Metot	R	RMSE	MAE	Tahmin Süresi (s)	R	RMSE	MAE	Tahmin Süresi (s)
RF	0,877	12,40	8,90	13,4	0,886	7,84	5,32	13,03
CART	0,807	15,17	11,24	**0,15**	0,860	8,59	5,99	**0,14**
SVR	0,849	13,61	9,69	0,51	0,882	8,05	5,43	0,50
KNN	0,838	14,10	9,76	0,60	0,869	8,24	5,83	0,59
ELM	0,857	13,22	9,87	0,74	0,875	8,06	5,63	0,71
ANFIS	**0,974**	**5,87**	**4,75**	1,60	**0,983**	**3,05**	**2,35**	2,18

Kirletici ve meteorolojik verilerin birlikte girdi değişkenleri olarak kullanılarak PM_{10} ve $PM_{2.5}$ tahmini yapıldığında en yüksek R değeri hem PM_{10} hem de $PM_{2.5}$ için ANFIS metodu ile ölçülmüştür. En düşük RMSE ve MAE hata değerlerine de yine ANFIS metodunda ulaşılmıştır. PM_{10} ve $PM_{2.5}$ değerlerinin tahmin edilmesinde RF yöntemi ANFIS metodunu takip etmektedir. PM_{10} için en kısa tahmin süresi 0,15 saniye ile CART metodunda ölçülürken, yaklaşık 13 saniye ile en uzun tahmin süresi RF metoduna aittir. RF yönteminin diğer yöntemlerden daha uzun sürede tahmin gerçekleştirmesinin sebebi bir topluluk öğrenme yöntemi olmasıdır. Yöntemlerin $PM_{2.5}$ tahmin performansları karşılaştırıldığında yine ANFIS modelinin gerçeğe en yakın tahminlerde bulunduğu ve PM_{10}'a göre daha düşük hata ile tahmin edildiği görülmektedir.

Sadece kirletici parametreler kullanılarak PM konsantrasyonları tahmin edilmiş model sonuçları Tablo 4.18'te verilmiştir.

Sadece kirletici parametreleri girdi değişkeni olarak kullanıp PM_{10} ve $PM_{2.5}$ tahmini yapıldığında, en yüksek korelasyon katsayısı yine ANFIS metodundan elde edilmiştir. Yöntemlerin RMSE değerleri incelendiğinde PM_{10} ve $PM_{2.5}$ için en düşük değer ANFIS metodu

ile tespit edilmiştir. MAE değerleri incelendiğinde en düşük değer PM_{10} için RF metoduna, $PM_{2.5}$ için ise SVR metoduna aittir. Modellerin tahmin süreleri incelendiğinde ise en hızlı tahmin yapan yöntemin CART olduğu görülmektedir. ANFIS modeli CART modeli kadar hızlı tahminlerde bulunmasa da PM_{10} için 1,2 saniye ve $PM_{2.5}$ için 2,28 saniye ile oldukça başarılı ve hızlı bir şekilde tahminleri gerçekleştirmiştir.

Tablo 4.18: Kirletici verilerden modellerin PM tahmin performansları.

	PM_{10}				**$PM_{2.5}$**			
Metot	R	RMSE	MAE	Tahmin Süresi (s)	R	RMSE	MAE	Tahmin Süresi (s)
RF	0,847	13,68	**9,99**	9,91	0,876	8,08	5,51	9,96
CART	0,807	15,17	11,24	**0,14**	0,860	8,59	5,99	**0,31**
SVR	0,825	14,57	10,51	0,49	0,884	8,01	**5,46**	0,72
KNN	0,811	15,02	10,92	0,59	0,845	8,81	6,08	0,84
ELM	0,833	14,19	10,75	0,72	0,874	8,12	5,63	1,16
ANFIS	**0,884**	**12,82**	10,27	1,20	**0,917**	**7,61**	6,18	2,28

Sadece meteorolojik parametreler kullanılarak PM konsantrasyonları tahmin edilmiş model sonuçları Tablo 4.19'te verilmiştir.

Tablo 4.19: Meteorolojik verilerden modellerin PM tahmin performansları.

	PM_{10}				**$PM_{2.5}$**			
Metot	R	RMSE	MAE	Tahmin Süresi (s)	R	RMSE	MAE	Tahmin Süresi (s)
RF	0,730	17,57	12,11	8,98	0,752	10,95	7,50	8,70
CART	0,672	19,01	13,70	**0,13**	0,735	11,22	7,69	**0,13**
SVR	0,583	21,76	14,62	0,50	0,641	13,42	8,70	0,48
KNN	0,693	18,69	12,80	0,60	0,718	11,49	8,08	0,58
ELM	0,520	22,08	15,55	0,73	0,595	13,38	9,17	0,70
ANFIS	**0,850**	**13,68**	**9,97**	47,94	**0,875**	**8,17**	**5,69**	47,33

Sadece meteorolojik veriler ile tahmin performansları incelendiğinde en yüksek R değerini PM_{10} ve $PM_{2.5}$ için ANFIS metodunda ölçülmüştür. En düşük RMSE ve MAE performansının her iki kirletici için de ANFIS metodunda olduğunu görülmektedir. Tahmin hızı performansını karşılaştırdığımızda en hızlı metot yine CART olurken en yavaş metot ise hem PM_{10} hem $PM_{2.5}$ için de 48 saniye yakın değerler ile ANFIS olmuştur. ANFIS modelinin tahmin hızı diğer modellerden daha yüksektir ancak diğer yöntemlere göre oldukça başarılı tahminler yaptığından 48 saniye göz ardı edilebilir bir süredir.

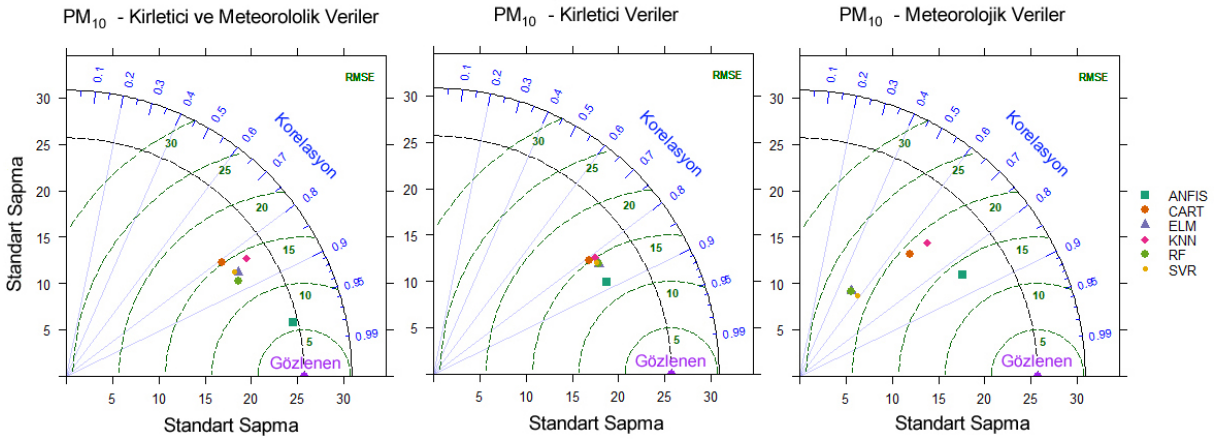
Sonuç olarak PM_{10} ve $PM_{2.5}$ konsantrasyonlarını başarılı bir şekilde tahmin etmek için hem farklı modeller geliştirildi hem de farklı girdi parametreleri kullanıldı. PM_{10} tahmininde 0,974 R değeri ile kirletici ve meteorolojik değişkenlerinin birlikte kullanılmasıyla en yüksek başarım ANFIS modeli ile elde edildi. Model girdi değişkenleri olarak sadece kirleticiler veya sadece meteorolojik veriler kullanıldığında da ANFIS modeli diğer modellerden daha başarılı tahminler yapmıştır (sırasıyla R=0,850 ve R=0,884). RMSE ve MAE değerleri karşılaştırıldığında ANFIS modelinin diğer yöntemlere göre oldukça düşük hatalar ile tahmin yaptığı açıkça görülmektedir. İstatistiksel karşılaştırmalar sonucunda PM_{10} tahmini için en başarılı metodun ANFIS olduğu ve ona en yakın metodun da RF olduğu sonucuna varılmıştır.

$PM_{2.5}$ tahmininde model performans sonuçları incelendiğinde, yine kirletici ve meteorolojik parametrelerin birlikte girdi olarak kullanıldığında ANFIS modelinin daha başarılı tahminler yaptığı görülmektedir (R=0,983, RMSE=3,05, MAE=2,35).

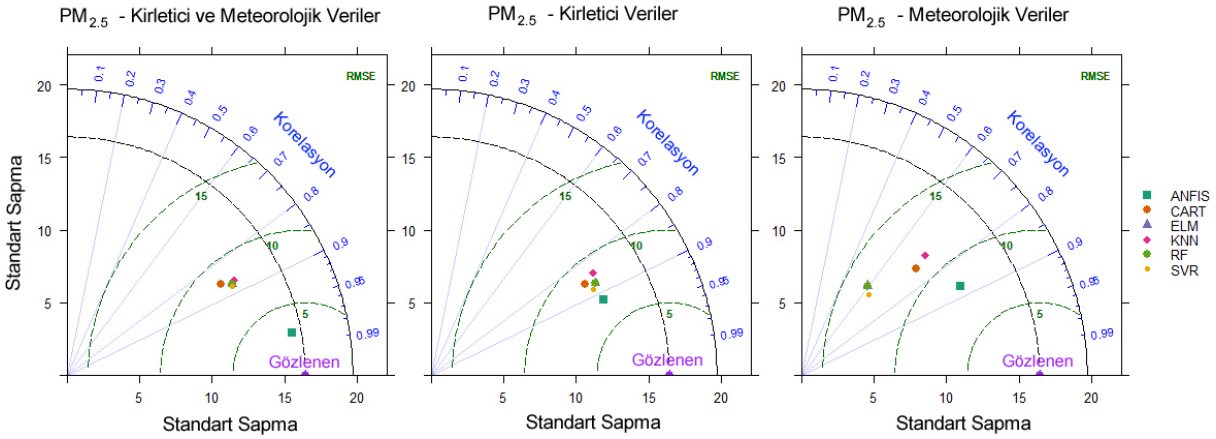
Gözlemlenen ve tahmin edilen verilerin arasındaki ilişkiyi grafiksel olarak özetlemek için Taylor diyagramları kullanılmaktadır. Bu diyagramda iki veri kümesi arasındaki benzerlik, korelasyon, RMSE değeri, standart sapmalarının oranı iki boyutlu grafik üzerinde tek bir nokta olarak gösterilir. Bu istatistiki veri bir modelin gerçek değeri ne kadar doğru simule ettiğini ölçmede kullanıldığı gibi modeller arasındaki performans karşılaştırmasının da hızlıca yapılmasını sağlar. Taylor diyagramı özellikle rakip modellerin değerlendirilmesinde ve genel performansı izlemede faydalıdır (Taylor, 2021).

Kirletici ve meteorolojik veriler kullanılarak RF, CART, SVR, KNN, ELM, ANFIS modelleri ile PM_{10} ve $PM_{2.5}$ kirleticileri tahmin edilmiş ve performans sonuçları Şekil 4.39 ve Şekil 4.40'taki Taylor diyagramında gösterilmiştir.

Taylor diyagramlarında PM tahmini için kullanılan metotların gerçek veriye yakınlık ve doğruluk açısından karşılaştırılmaktadır. Hem PM_{10} hem de $PM_{2.5}$ tahmininde ANFIS metodunun korelasyon katsayısının daha yüksek ve RMSE oranlarının daha düşük olduğunu görülmektedir. Bu diyagramlar ile PM değerlerini tahmin etmede ANFIS metodunun diğer metotlara göre daha başarılı olduğu açıkça görülmektedir.



Şekil 4.39: PM_{10} model tahmin başarı karşılaştırması.



Şekil 4.40: $PM_{2.5}$ model tahmin başarı karşılaştırması.

Hava kirliliğinin en büyük birleşeni olan partikül madde kirleticilerinin önemi göz önüne alındığında, bu tez çalışmasında en başarılı tahmin modelinin belirlenmesi amaçlanmıştır. Girdi verilerin seçimi, tahmin modellerinin başarısını etkilediği görülmüş olup hava kirleticileri olan SO_2, NO_2, NO, NO_x, CO ile meteorolojik parametreler olan sıcaklık, rüzgâr hızı, rüzgâr yönü ve toplam yağış parametrelerinin birlikte kullanılması ile en başarılı sonuçlar elde edilmiştir. Model başarı performanslarının karşılaştırılmasında R, RMSE ve MAE istatistiksel ölçütler kullanılmış olup, bunlara göre en başarılı tahmin modelinin ANFIS olduğu tespit edilmiştir. Tez kapsamında kullanılan veri seti için ANFIS metodu kullanılarak PM_{10} ve $PM_{2.5}$ konsantrasyonunun başarılı bir şekilde tahmin edilebildiği deneysel olarak ortaya konmuştur.

5. TARTIŞMA

Tez çalışmasının bu kısımda 4. bölümde sunulan bulgular ışığında değerlendirmeler yapılmıştır. Çalışma bölgesinde hava kirliliğinin nedenleri tartışılarak oluşturulan modellerde tespit edilen tahmin sonuçları literatür araştırması sonuçları ile kıyaslanmıştır.

Mevsimsel SO_2 konsantrasyonları ile PM konsantrasyonlarının paralel hareket ettiği belirlenmiştir. Bu durum PM ve SO_2 kirliliği kaynağının aynı olduğu sonucunu vermektedir. SO_2 emisyonlarının fosil yakıtların yanma ürünü olduğu bilindiğine göre, PM konsantrasyonlarının da ısınma kaynaklı olduğu söylenebilmektedir. Ayrıca sıcaklığın artış gösterdiği aylarda PM konsantrasyonlarında görülen azalış, ısınma amacıyla kullanılan fosil yakıtların PM kirliliğine neden olabileceğini göstermektedir.

SO_2 kirliliğine benzer bir şekilde, NO, NO_x ve NO_2 konsantrasyonlarındaki aylık değişim ile PM konsantrasyonları arasındaki aylık değişimin pozitif yönde olduğu görülmüştür. Yoğun trafiğin olduğu bölgelerde ve yol kenarlarında NO, NO_x ve NO_2 emisyonlarının yüksek olması ve PM ile olan pozitif ilişkisi beklenen bir durumdur. Kış aylarında artan ve yaz aylarında azalan NO, NO_x ve NO_2 konsantrasyon verilerine dayanılarak ısınma kaynaklı NO, NO_x ve NO_2 emisyonu varlığı olduğu gibi trafik yoğunluğunun yaz aylarında azaldığı çıkarımı da yapılabilmektedir.

Ayrıca PM_{10} ve $PM_{2.5}$ kirleticilerinin SO_2, NO, NO_2 ve NO_x kirleticileri ve meteorolojik olarak rüzgâr yönü ile pozitif ve yüksek korelasyon ilişkisine sahip olduğu, sıcaklık, rüzgâr hızı ve yağış parametreleri ile negatif korelasyon ilişkisine sahip olduğu tespit edilmiştir. Araştırma sonuçlarına göre NO_x kirleticisinin ÇŞB'nin (2008) belirlemiş olduğu yıllık ortalama limit değeri aştığı görülmüştür.

CO konsantrasyonu 2016 yılından 2019 yılına kadar adım adım artış göstermiştir. Eksik yanma ürünü olarak oluşan CO'nun yıllara göre artışı, yanma proseslerinin bölgede arttığı yani hem ısınma hem de ulaşım kaynaklı hava kirliliği artışının söz konusu olduğu belirlenmiştir.

Rüzgâr hızının artışı kirleticilerin dağılımını olumlu yönde etkileyen bir faktördür. Rüzgâr yönü ise emisyon kaynaklarının tayininde yol gösterici olmaktadır. Yaz aylarında hâkim rüzgâr

yönünün kış aylarına göre farklılık gösterdiği gözlenirken, rüzgâr hızındaki mevsimsel değişim aralığı dar kalmaktadır. Bu durum yaz aylarında azalan SO_2, NO, NO_x ve NO_2 konsantrasyonlarındaki azalmanın nedeni de olabilmektedir. Hâkim rüzgâr yönünün poyraz olduğu çalışma bölgesinin kuzeydoğusunda ulaşım ve şehirleşme ağırlık göstermektedir. Isınma amaçlı doğalgazın yüksek oranda kullanıldığı bölgede, ele aldığımız 2016 ile 2019 yılları arasındaki ölçüm sonuçlarına göre, PM_{10} kirliliğinin günlük limit aşım sayısı her yıl dikkat çekici oranda artış göstermiştir. $PM_{2.5}$ kirleticisi ise DSÖ'nün belirlemiş olduğu yıllık ortalama limit değerlerin yaklaşık iki katı seviyesinde kirliliğe sahip olduğu görülmektedir.

Tahmin sonuçlarının gerçek değerlere göre doğruluğunu tespit etmek ve metotların kıyaslamasını yapabilmek için kullanılan istatistiksel paramatreler olan MAE ve RMSE bir tahmin kümesindeki hatalardaki varyasyonu teşhis etmek amacıyla birlikte kullanılabilir. RMSE değeri her zaman MAE değerinden büyük veya eşit olacaktır, aralarındaki fark ne kadar büyük ise örnekteki münferit hatalardaki varyansı o kadar büyük olur. RMSE değeri eğer MAE değerine eşit ise tüm hataların aynı büyüklükte olduğu söylenebilir.

Tablo 5.1'de sunulan çalışmalarda, tez çalışmasına benzer olarak, hava kirletici parametreler ile meteorolojik parametreler kullanılmıştır. MAE değeri beklenildiği üzere her zaman RMSE değerinden düşük sonuçlar elde edilmiştir. Elde edilen hata değerleri kabul edilebilir ölçüde değerlendirilebilir.

R yazılımı kullanılarak altı farklı yapay zekâ metodu ve çalışma bölgesinde yüksek konsantrasyonda ölçülen PM_{10} ile $PM_{2.5}$ kirleticileri için hazırlanan üç farklı veri grubuna uygulanmıştır. Hazırlanan veri grupları olan kirletici veriler, meteorolojik veriler, kirletici ve meteorolojik veriler ile ayrı ayrı PM_{10} ve $PM_{2.5}$ tahmini için yapılan modelleme sonucunda 0,595-0,983 aralığında R değeri, 3,05-22,08 aralığında RMSE değeri ve 2,35-15,55 aralığında MAE değeri elde edilmiştir.

Hava kirletici veriler ve meteorolojik verilerin birlikte kullanıldığı analiz sonuçlarında en başarılı tahmin metodu olarak tespit edilen ANFIS metodu ile literatür çalışmaları kıyaslandığında $PM_{2.5}$ için elde ettiğimiz 2,35 MAE değerinin benzer çalışmalarda 23,34 (Bhardwaj ve Pruthi, 2020) ve 4,22 (Ausati ve Amonolhali, 2016) sonuçlarına göre daha verimli olduğu görülmüştür. Aynı kıyaslamayı RMSE değeri için yaptığımızda elde edilen 3,05 değerinin Bhardwaj ve Pruthi'nin (2020) tespit ettiği 38,7, Ausati ve Amonolhali'nin (2016) tespit ettiği 5,28 sonucuna kıyasla daha düşük hata değerine sahip olduğu görülmektedir. Ausati

ve Amonolhali'nin (2016) elde ettiği 0,75 R^2 değeri ve Bhardwaj ve Pruthi'nin (2020) elde ettiği 0,7 R^2 değerlerine kıyasla $PM_{2.5}$ için elde ettiğimiz 0,983 R değeri oldukça verimli tahmin sonucunun elde edildiğini ifade etmektedir.

Tablo 5.1: Literatür kıyaslaması.

Referans	Kullanılan Parametreler	Kullanılan Algoritma	MAE	RMSE	R / R^2
Bu Tez Çalışması	PM_{10}, $PM_{2.5}$, SO_2, NO, NO_2, NO_x, CO, rüzgâr hızı, rüzgâr yönü, sıcaklık, yağış	RF	5,32 ($PM_{2.5}$) 8,9 (PM_{10})	7,84 ($PM_{2.5}$) 12,4 (PM_{10})	R: 0,886 ($PM_{2.5}$) R: 0,877 (PM_{10})
		CART	5,99 ($PM_{2.5}$) 11,24 (PM_{10})	8,59 ($PM_{2.5}$) 15,17 (PM_{10})	R: 0,86 ($PM_{2.5}$) R: 0,807 (PM_{10})
		SVR	5,43 ($PM_{2.5}$) 9,69 (PM_{10})	8,05 ($PM_{2.5}$) 13,61 (PM_{10})	R: 0,882($PM_{2.5}$) R: 0,849 (PM_{10})
		KNN	5,83 ($PM_{2.5}$) 9,76 (PM_{10})	8,24 ($PM_{2.5}$) 14,1 (PM_{10})	R: 0,869 ($PM_{2.5}$) R: 0,838 (PM_{10})
		ELM	5,63 ($PM_{2.5}$) 9,87 (PM_{10})	8,06 ($PM_{2.5}$) 13,22 (PM_{10})	R: 0,875 ($PM_{2.5}$) R: 0,857 (PM_{10})
		ANFIS	2,35 ($PM_{2.5}$) 4,75 (PM_{10})	3,05 ($PM_{2.5}$) 5,87 (PM_{10})	R: 0,983 ($PM_{2.5}$) R: 0,974 (PM_{10})
Yoo ve diğ. (2019)	PM_{10}, $PM_{2.5}$, O_3, NO_2, CO, SO_2, rüzgâr hızı, rüzgâr yönü, sıcaklık, en düşük sıcaklık nem, yağış	RF	4,4 ($PM_{2.5}$) 6,6 (PM_{10})	6,4 ($PM_{2.5}$) 11 (PM_{10})	-
Lovric ve diğ. (2021)	PM_{10}, O_3, NO_2, sıcaklık, yağış, rüzgâr hızı, rüzgâr yönü, basınç	RF	-	5,33-13,44	R^2: 0,71
Bisht ve Seeja, (2018)	PM_{10}, $PM_{2.5}$, NO_2, CO, O_3, sıcaklık, yağış, rüzgâr yönü	ELM	-	24 ($PM_{2.5}$) 18 (PM_{10})	-
Bozdağ ve diğ. (2020)	PM_{10}	SVR	14,6-22,9	22,5-69,9	R^2: 0,56
		RF	14,4-27,1	22,1-69,1	R^2: 0,61
		KNN	15,5-26,7	23,4-70,3	R^2: 0,57
Bhardwaj ve Pruthi (2020)	$PM_{2.5}$	ANFIS	23,34	38,70	R^2: 0,7
Zhai ve Chen (2018)	$PM_{2.5}$, CO, NO_2, SO_2, O_3, HKİ, sıcaklık, günlük güneşlenme süresi, rüzgâr hızı, rüzgâr yönü	SVR	18,92	27,95	R^2: 0,85
Du ve diğ. (2020)	$PM_{2.5}$, PM_{10}, SO_2, HKİ	ELM	9,16-15,62 ($PM_{2.5}$) 14,37-23,69 (PM_{10})	12,07-20,25 ($PM_{2.5}$) 19,40-31,04 (PM_{10})	R: 0,49-0,67 ($PM_{2.5}$) R: 0,3-0,64 (PM_{10})
Ausati ve Amanolhali (2016)	$PM_{2.5}$, PM_{10}, CO, NO_2, SO_2, O_3, en düşük sıcaklık, en yüksek sıcaklık, yağış, nem, rüzgâr hızı	ANFIS	4,22 ($PM_{2.5}$)	5,28 ($PM_{2.5}$)	R^2: 0,75 ($PM_{2.5}$)

Tez çalışmasında ikinci en yüksek performansı gösteren RF metodu sonuçlarına göre PM_{10} için elde edilen 0,877 R değerinin Lovric ve diğerlerinin (2021) elde ettiği 0,71 R^2 değerinden, Bozdağ ve diğerlerinin elde ettiği 0,61 R^2 değerinden daha yüksek olduğu tespit edilmiştir. 8,9 değerindeki MAE değeri literatürde elde edilmiş 6,6 (Yoo ve diğ., 2019) ve 14,6-27,1 (Bozdağ ve diğ., 2020) değerlerinden düşük tespit edilmiştir. Elde edilen 12,4 RMSE değerinin ise 5,33-13,44 (Lovric ve diğ., 2021), 11 (Yoo ve diğ., 2019) ve 22,1-69,1 (Bozdağ ve diğ., 2020) değerlerine göre anlamlı ve başarılı olduğu söylenebilmektedir.

Bu tez çalışmasında kullanılan veriler ve metotlar ile yukarıda verilmiş olan literatürle uyumlu anlamlı sonuçlar elde edildiği görülmektedir. Literatürde verimli sonuçlar elde edilen yapay zekâ metotları kullanılarak karşılaştırılmış ve en sık kayıt altına alınan kirletici dağılımını etkileyebilecek önemli meteorolojik veriler kullanılmıştır. Tespit edilen sonuçlar yapmış olduğumuz çalışmanın oldukça başarılı ve uygulanabilir olduğunu ispatlamaktadır.

6. SONUÇ VE ÖNERİLER

Günümüzde insanlığın büyük bir bölümü yaşamlarını şehirlerde devam ettirmektedir. Gelecekte şehirde yaşam oranı artacağı beklendiği gibi şehirlerinde yüksek nüfuslara ulaşacağı ön görülmektedir. Bu durum yaşam ortamımız olan şehirlerde birçok soruna neden olurken insani aktiviteler olan ulaşım, ısınma ve sanayi kaynaklı hava kirliliği kentsel hava kalitesini olumsuz etkilemektedir.

Hava kirliliği, dünyada sağlık açısından beşinci risk faktörü olarak görülmektedir (Forouzanfar ve diğ., 2015). Dünya çapında aerodinamik çapı 10 μm'den küçük (PM_{10}) ve 2,5 μm'den küçük ($PM_{2.5}$) partikül madde, ozon (O_3), azot dioksit (NO_2) vb. kirleticiler dünyanın birçok yerinde yüksek konsantrasyonlarda ölçülerek kayıtlara geçmiştir (DSÖ, 2016). Bu sonuç hava kirliliği araştırmalarına yönelik dikkati arttırmaktadır.

Şehir ölçeğinde hava kalitesinin kontrol altında tutulabilmesi ve hava kirliliğinin oluşumunun önlenebilmesi için hava kirliliğinin ölçümlerle takip edilmesi ve elde edilen sonuçlara istinaden gereken önleyici politikaların geliştirilmesi gerekmektedir. Zamansal eğilimler, mekansal değişkenlik ve hava kirliliğini etkileyen faktörler üzerine yapılan çalışmalar kentsel çevrede her zaman dikkat çekmekte ve önem arz etmektedir.

Hava kirliliği problemlerini çözmek ve strateji geliştirmek adına ilgili otoriteler ve bilimsel çalışmalarda bulunan araştırmacılar hava kirleticilerini takip ve analiz etmeye odaklanmışlardır. Ulusal ve uluslararası değerlendirmeler sonucu hava kalitesini belirlemek için ölçülmesi gereken parametreler belirlenmiştir. Azot oksitler (NO, NO_2, NO_x), kükürt dioksit (SO_2), ozon (O_3), karbon monoksit (CO) ve partikül madde (PM_{10}, $PM_{2.5}$) ölçüm sonuçlarına göre hava kalitesi tayin edilmektedir. Hava kalitesinin korunması ve iyileştirilmesi otoritelerin sorumluluğunda olsa da doğrudan halk sağlığına etkisi olduğundan hava kalitesi hakkında güncel bilgileri kamuoyuna sunması da bir sorumluluktur.

Türkiye'de endüstrileşmenin gelişimi Çerkezköy Organize Sanayi Bölgesi ve Kapaklı Organize Sanayi Bölgesi'nin yer aldığı, çalışma alanımız olan, Tekirdağ ilinin Çerkezköy ve Kapaklı ilçelerinde iş imkanlarının artmasına, dolayısıyla şehirleşmenin ve göçle birlikte Türkiye ortalaması üzerinde nüfus artış hızının görülmesine sebep olmuştur. Nüfusun hızlı artışı,

yapılaşmanın artması ve ulaşım açısından Çorlu, Vize ve İstanbul güzergahlarının merkezinde yer alan söz konusu bölge için hava kalitesindeki değişiminin takibi önem kazanmıştır. Trafik yoğunluğunun artışı, endüstri tesisleri ve nüfus artışı etkisi ile her geçen gün kentsel hava kirliliği de artış göstermekte hem trafik kaynaklı hem endüstri kaynaklı hem de ısınma kaynaklı hava kirliliği açısından alıcı ortam konumunda olan Çerkezköy ve Kapaklı bölgelerinde daha fazla insanın hava kirliğinden etkilenmesi söz konusu olmaktadır.

Çalışma bölgesinde elde edilen hava kirletici verilerinin limit değerlerin üzerinde olması neticesinde hava kirliliği üzerine araştırma çalışmalarının yapılması gerektiğinin önemi ortaya çıkmıştır. Bu tez çalışmasında, en önemli hava kirleticilerden olan PM_{10}, $PM_{2.5}$, SO_2, NO, NO_2, NO_x ve CO bileşenlerinin zamansal değişimi incelenmiş, PM bileşenlerinin diğer hava kirleticileri ve meteorolojik veriler olan sıcaklık, rüzgâr yönü, rüzgâr hızı, toplam yağış ile ilişkileri araştırılmış ve bu kirleticilerin farklı yapay zekâ algoritmalarıyla modellenmesi amaçlanmıştır. Hava kalitesi indeksinin uzun vadeli değişimi incelenmiş ve COVID-19 pandemisi sürecinin hava kalitesi üzerine etkileri araştırılmıştır. Ayrıca çalışma bölgesi ölçüm verileri benzer ve zıt yerleşime sahip ölçüm istasyonları ile kıyaslanmıştır. Çalışmada elde edilen bulgular aşağıda özetlenmiştir.

- Hava kirleticilerin zamansal dağılımı incelendiğinde, kirleticilerin zaman zaman limit değerlerin üzerine çıktığı gözlemlendi (Şekil 4.30, Şekil 4.31).
- PM_{10} ve $PM_{2.5}$ konsantrasyonlarının DSÖ'nün belirlemiş olduğu yıllık ortalama limit değerin yaklaşık iki kat üzerinde ölçüldüğü tespit edilmiştir. Ayrıca 2017, 2018 ve 2019 yıllarında PM_{10}, ulusal günlük ortama konsantrasyon sınır değer aşım sayısının üzerinde günlük konsantrasyona ve 2019 yılında ulusal yıllık ortama sınır değerinin üzerinde konsantrasyona sahip olduğu görüldü.
- Yıllık ortalama SO_2 konsantrasyonunun 2016 yılında ulusal sınır değerin üzerinde olduğu tespit edilirken yıllık ortalama NO_x konsantrasyonunun çalışma süresi kapsamında her yıl ulusal sınır değerin üzerinde kirliliğe sahip olduğu tespit edildi.
- Çalışma alanı olan Çerkezköy ölçüm istasyonuna sanayi, ulaşım ve kentsel yerleşim açısından benzer konumda yer alan Kocaeli Dilovası, Konya Selçuklu ve Kayseri OSB ölçüm istasyonlarında da günlük ve yıllık ortalama limit değerlerin üzerinde PM_{10} ve $PM_{2.5}$ konsantrasyonu tespit edildi.
- Çerkezköy ölçüm istasyonuna kıyasla sanayi, ulaşım ve kentsel yerleşimden uzakta konumlanmış Yalova Armutlu istasyonunda ise ulusal limitlerin çok altında günlük ve

yıllık ortalama kirletici konsantrasyonu değerleri ölçümü yapılırken ölçülen yıllık ortalama PM_{10} konsantrasyon değeri dört yıllık çalışma döneminin sadece bir yılında DSÖ'nün belirlediği yıllık ortalama limit değerin altında kalırken, $PM_{2.5}$ konsantrasyon değerleri çalışma süresince DSÖ'nün belirlediği yıllık ortalama limit değerin üstünde tespit edilmiştir.

- Çerkezköy ölçüm istasyonu ile kıyaslanan istasyonlar arasında sadece Kocaeli Dilovası ölçüm istasyonunda 2017 yılında yıllık ortalama SO_2 konsantrasyonu ulusal limitler üzerinde çıkmıştır.
- Çerkezköy ve kıyaslanan ölçüm istasyonlarında yıllık ortalama sıcaklığın değişimi ile ölçülen SO_2 konsantrasyonun ters korelasyonda olduğu görülmüştür (Şekil 4.23). Bu sonucun ısınmadan kaynaklı SO_2 kirliliğinin oluştuğunu diğer bir deyişle ısınma amacıyla kömür kullanımından kaynaklandığı düşünülmektedir.
- Kocaeli Dilovası ölçüm istasyonunda 2018 yılında limit değere çok yakın olmakla birlikte, Konya Selçuklu ölçüm istasyonu ile birlikte çalışma süresince her yıl ulusal yıllık ortalama NO_x limitinin üzerinde konsantrasyona sahip olduğu tespit edildi.
- Çalışma süresi boyunca her yıl Konya Selçuklu ölçüm istasyonunda ve 2016 yılında Kocaeli Dilovası ölçüm istasyonunda ulusal yıllık ortalama NO_2 limiti üzerinde kirletici konsantrasyonu ölçülmüştür. Çerkezköy ölçüm istasyonu ölçüm sonuçlarında olduğu gibi yüksek konsantrasyona sahip NO_x ve NO_2'nin varlığı, söz konusu bölgelerde ulaşımdan kaynaklı hava kirliliğinin önemli bir kirletici kaynağı olduğunu göstermektedir.
- Yalova Armutlu ölçüm istasyonunda ölçülen SO_2, NO_x ve NO_2 konsantrasyonlarının ulusal yıllık ortalama limitlerin çok altında olduğu görülmüştür. Sanayi, kentleşme ve ulaşımın yoğun olduğu bölgelere kıyasla yoğunluktan uzak bölgelerde hava kalitesinin olumlu anlamda farklı olduğu, sanayi bölgelerinin ve yerleşim alanlarının planlaması yapılırken ve fosil yakıt kullanılırken hava kalitesinin odak noktasına alınmasının önemi görülmektedir.
- Hava kalitesi indeksi değerleri incelendiğinde 2016-2020 yılları arasında hava kalitesinin ağırlıklı olarak orta ve iyi seviyede olduğu görülmektedir. Ayrıca 2016 ve 2017 yıllarına nispeten 2019 ve 2020 yıllarında hava kalitesi indeks değerlerinin daha iyi seviyede olduğu söylenebilir.
- 2019-2020 yılları Nisan-Mayıs döneminde hava kalitesindeki değişim ile ÇOSB doğalgaz ve elektrik tüketim değerleri karşılaştırıldığında, 2020 yılında yaşanan

COVID-19 pandemisi sonucu sanayide kullanılan doğalgaz ve elektrik tüketiminde görülen azalışı 2019 yılındaki hava kalitesi değerleri ile 2020 yılına ait hava kalitesi değerleri arasındaki farkın oluşmasına sebep olmuştur. 2019 yılına kıyasla söz konusu 2020 yılı Nisan-Mayıs döneminde hava kirliğine etken olan kirletici konsantrasyonlarında azalma gözlemlenmiş olup hava kalitesi adına olumlu sonuçlar tespit edilmiştir. Hava kalitesinin izlenmesine yönelik çalışmaların artması bölgesel ve ulusal ölçekte hava kirliliğine karşı alınacak önlemlerin ve yol haritasının belirlenmesine ışık tutacaktır.

- NO, NO_x, NO_2 ve SO_2 kirleticileri ile rüzgâr yönünün (RY) yıllara göre benzer artış ve azalış gösterdiği dikkat çekmektedir. Bu durum, beklenildiği üzere, RY ile kirleticilerin atmosferdeki hareketi arasında öneli bir ilişki olduğunu ortaya koymaktadır.
- PM_{10} ile kirletici ve meteorolojik veriler içinde en yüksek korelasyona sahip kirletici 0,81 ile NO_2 olmuştur (Şekil 4.26). Ayrıca PM_{10} parametresi ile NO_x ve SO_2 arasında kuvvetli bir ilişki olduğu görüldü (sırasıyla 0,76 ve 0,74). Benzer korelasyon ilişkisi $PM_{2.5}$ ve hava kirleticiler arasında da gözlemlenmiştir (Şekil 4.27).
- Şekil 4.39'da sunulan model çıktıları ve istatistiksel veriler incelendiğinde, sadece kirletici konsantrasyonları kullanılarak, sadece meteorolojik veriler kullanılarak, kirletici konsantrasyonları ile meteorolojik verilerin birlikte kullanıldığı üç farklı veri grubu ile yapılan PM_{10} ve $PM_{2.5}$ değerini tahmin etme çalışmasında yapay zekâ yöntemleri arasında ANFIS yönteminin en yüksek hassasiyete sahip olduğu görüldü.
- Kirletici ve meteorolojik parametrelerin birlikte model girdi değişkeni olarak kullanılması, sadece kirletici veya sadece meteorolojik parametrelerin kullanılmasından daha başarılı tahmin sonuçları vermiştir.

Hava kirleticilerin atmosferdeki dağılımı ve birbirleriyle olan ilişkileri çok sayıda araştırmacı tarafından incelenmiştir. Atmosferin yapısı ve boyutları nedeniyle hava kirleticilerin takibi ve birbiriyle olan ilişkileri karmaşık bir yapıdadır. Bu nedenle hava kirleticilerin takibinde modelleme çalışmaları önem arz etmektedir. Bu çalışmada elde edilen sonuçlar önemli bir hava kirletici parametre olan PM bileşenlerinin yapay zekâ yöntemleriyle başarılı bir şekilde tahmin edilebileceğini gösterdi. Yapay zekâ yöntemlerinin en büyük avantajları farklı model yapıları ve farklı model değişkenleri ile başarılı sonuçlar elde edilmesidir. Bu bakımdan bu çalışmanın diğer araştırmacılara ilham olacağı düşünülmektedir.

KAYNAKLAR

AB 2008. Directive 2008/50/EC of the European Parliament and of the Council of 21 May 2008 on ambient air quality and cleaner air for Europe. Official Journal of the European Union: Avrupa Birliği Parlamentosu.

ALEIXANDRE, M., SAYAGO, I., HORRILLO, M. C., FERNÁNDEZ, M. J., ARÉS, L., GARCÍA, M., SANTOS, J. P. & GUTIÉRREZ, J. 2004. Analysis of neural networks and analysis of feature selection with genetic algorithm to discriminate among pollutant gas. *Sensors & Actuators: B. Chemical,* 103**,** 122-128.

ALPAYDIN, E. & BACH, F. 2014. *Introduction to Machine Learning,* Cambridge, Unıted States, MIT Press.

ALTMAN, N. S. 1992. An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician,* 46**,** 175-185.

AUSATI, S. & AMANOLLAHI, J. 2016. Assessing the accuracy of ANFIS, EEMD-GRNN, PCR, and MLR models in predicting $PM_{2.5}$. *Atmospheric Environment,* 142**,** 465-474.

BAHRAMI ASL, F., LEILI, M., VAZIRI, Y., SALAHSHOUR ARIAN, S., CRISTALDI, A., OLIVERI CONTI, G. & FERRANTE, M. 2018. Health impacts quantification of ambient air pollutants using AirQ model approach in Hamadan, Iran. *Environmental Research,* 161**,** 114-121.

BAŞOĞLU, B. & BULUT, M. 2017. Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Journal of the Faculty of Engineering & Architecture of Gazi University,* 32.

BELL, M. L., DOMINICI, F., EBISU, K., ZEGER, S. L. & SAMET, J. M. 2007. Spatial and temporal variation in PM(2.5) chemical composition in the United States for health effects studies. *Environmental health perspectives,* 115**,** 989-995.

BHARDWAJ, R. & PRUTHI, D. 2020. Evolutionary Techniques for Optimizing Air Quality Model. *Procedia Computer Science,* 167**,** 1872-1879.

BISHT, M. & SEEJA, K. R. 2018. *Air Pollution Prediction Using Extreme Learning Machine: A Case Study on Delhi (India),* Singapore, Springer Singapore.

BM 2019. *World Urbanization Prospects, The 2018 Revision,* Birleşmiş Milletler, Ekonomi ve Sosyal İşler Departmanı.

BOŞGELMEZ, A., PASLI, N., BOŞGELMEZ, İ. İ., KAYNAŞ, S. & SAVAŞÇI, S. 2000. *Ekoloji I*.

BOZDAĞ, A., DOKUZ, Y. & GÖKÇEK, Ö. B. 2020. Spatial prediction of PM_{10} concentration using machine learning algorithms in Ankara, Turkey. *Environmental Pollution,* 263.

BREIMAN, L., FRIEDMAN, J. H., OLSHEN, R. A. & STONE, C. J. 2017. *Classification and regression trees*, Routledge.

CEBESOY, T. 1995. Madencilikte bilgisayara dayalı yapay zeka teknikleri uygulamaları. *Türkiye 14. Madencilik Kongresi*

CHEN, G., LI, S., KNIBBS, L. D., HAMM, N. A. S., CAO, W., LI, T., GUO, J., REN, H., ABRAMSON, M. J. & GUO, Y. 2018. A machine learning method to estimate $PM_{2.5}$ concentrations across China with remote sensing, meteorological and land use information. *Science of The Total Environment,* 636**,** 52-60.

CİHAN, P. 2020. Fuzzy Rule-Based System for Predicting Daily Case in COVID-19 Outbreak. IEEE.

CİHAN, P., KALIPSIZ, O. & GÖKÇE, E. 2017. Hayvan hastalığı teşhisinde normalizasyon tekniklerinin yapay sinir ağı ve özellik seçim performansına etkisi*.,* 12**,** 59-70.

ÇERKEZKÖY. 2021. *Çerkezköy Hakkında* [Online]. Çerkezköy Belediyesi. https://www.cerkezkoy.bel.tr [Erişim tarihi: 22 Temmuz 2021].

ÇOSB 2020. *Tüketimler* [Online]. Çerkezköy Organize Sanayi Bölge Müdürlüğü. https://cosb.org.tr/tuketimler/ [Erişim tarihi: 30 Ağustos 2020].

ÇOSB 2022. *Tarihçe* [Online]. Çerkezköy Organize Sanayi Bölge Müdürlüğü. https://cosb.org.tr/tarihce/ [Erişim tarihi: 31 Mart 2022].

ÇŞB 2008. Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği. Resmi Gazete: T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı.

ÇŞB 2020. Bölgesel İklim Değişikliği Eylem Planları. Ankara: T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı.

DE, A. K. & DE, A. K. 2009. *Environment and Ecology,* New Delhi, New Age International.

DEO, R. C. & ŞAHIN, M. 2015. Application of the extreme learning machine algorithm for the prediction of monthly Effective Drought Index in eastern Australia. *Atmospheric Research,* 153**,** 512-525.

DILORETO, D. & CORCORAN, I. 2012. *Carbon Monoxide: Sources, Uses, and Hazards,* New York, Nova Science Publishers, Inc.

DJEBBRII, N. & ROUAINIA, M. 2018. Prediction of industrial pollution by radial basis function networks. *Environment Protection Engineering,* 44**,** 153-164.

DOU, X. & YANG, Y. 2018. Estimating forest carbon fluxes using four different data-driven techniques based on long-term eddy covariance measurements: Model comparison and evaluation. *Science of the Total Environment,* 627**,** 78-94.

DRUCKER, H., BURGES, C. J., KAUFMAN, L., SMOLA, A. & VAPNIK, V. 1996. Support vector regression machines. *Advances in neural information processing systems,* 9.

DSÖ 2006. *Air Quality Guidelines: Global Update 2005. Particulate Matter, Ozone, Nitrogen Dioxide and Sulfur Dioxide,* Europe, SWITZERLAND, Dünya Sağlık Örgütü, Avrupa Bölge Ofisi.

DSÖ 2016. WHO's Ambient Urban Air Pollution database – Update 2016. https://cdn.who.int/media/docs/default-source/air-quality-database/aqd-2016/aap_database_methods_2016_v03.pdf?sfvrsn=b71455b4_3 [Erişim tarihi: 6 Şubat 2022].

DSÖ 2020. *Ambient air pollution* [Online]. Dünya Sağlık Örgütü. www.who.int/health-topics/air-pollution#tab=tab_2 [Erişim tarihi: 22 Temmuz 2020].

DSÖ 2021. *World health statistics 2021: monitoring health for the SDGs, sustainable development goals.*, Dünya Sağlık Örgütü.

DU, P., WANG, J., HAO, Y., NIU, T. & YANG, W. 2020. A novel hybrid model based on multi-objective Harris hawks optimization algorithm for daily $PM_{2.5}$ and PM_{10} forecasting. *Applied Soft Computing Journal,* 96.

EPA 1992. Term of Environment Birleşik Devletler Çevre Koruma Ajansı.

EPA 2018. Technical Assistance Document for the Reporting of Daily Air Quality - the Air Quality Index (AQI). Birleşik Devletler Çevre Koruma Ajansı.

FENG, R., ZHENG, H.-J., ZHANG, A.-R., HUANG, C., GAO, H. & MA, Y.-C. 2019. Unveiling tropospheric ozone by the traditional atmospheric model and machine learning, and their comparison:A case study in hangzhou, China. *Environmental pollution (Barking, Essex : 1987),* 252**,** 366-378.

FOROUZANFAR, M. H., ALEXANDER, L., ANDERSON, H. R., BACHMAN, V. F., BIRYUKOV, S., BRAUER, M., ve diğ. 2015. Global, regional, and national comparative risk assessment of 79 behavioural, environmental and occupational, and metabolic risks or clusters of risks in 188 countries, 1990–2013: a systematic analysis for the Global Burden of Disease Study 2013. *The Lancet,* 386**,** 2287-2323.

GILL, J., SINGH, J., OHUNAKIN, O. S., ADELEKAN, D. S., ATIBA, O. E., NKIKO, M. O. & ATAYERO, A. A. 2020. Adaptive neuro-fuzzy inference system (ANFIS) approach for the irreversibility analysis of a domestic refrigerator system using LPG/TiO 2 nanolubricant. *Energy Reports,* 6**,** 1405-1417.

GOLDIZEN, F. C., SLY, P. D. & KNIBBS, L. D. 2016. Respiratory effects of air pollution on children. *Pediatr Pulmonol,* 51**,** 94-108.

GÖKTAŞ, A. & YENIAY, Ö. 2003. Doğrusal Regresyonda En İyi Altküme Seçimine Genetik Algoritma Yaklaşımı. *Gazi University Journal of Science,* 16.

GUO, C. & CUI, Y. 2022. Utilizing artificial neural network to simulate and predict the hydraulic performance of free water surface constructed wetlands. *Journal of Environmental Management,* 305**,** 114334.

GUO, H., WEI, J., LI, X., HO, H. C., SONG, Y., WU, J. & LI, W. 2021. Do socioeconomic factors modify the effects of PM_1 and SO_2 on lung cancer incidence in China? *Science of the Total Environment,* 756.

GÜLSÜN, B., TUZKAYA, G. & DUMAN, C. 2009. Genetik algoritmalar ile tesis yerleşimi tasarımı ve bir uygulama. *Doğuş Üniversitesi Dergisi,* 10**,** 73-87.

GÜRSAKAL, N. 2018. *Makine Öğrenmesi*, Dora Yayınevi.

HAMANAKA, R. B. & MUTLU, G. M. 2018. Particulate matter air pollution: effects on the cardiovascular system. *Frontiers in endocrinology,* 9**,** 680.

HAMPSON, N. B., PIANTADOSI, C. A., THOM, S. R. & WEAVER, L. K. 2012. Practice recommendations in the diagnosis, management, and prevention of carbon monoxide poisoning. *Am J Respir Crit Care Med,* 186**,** 1095-101.

HEIL, A. 1998. Air Pollution Caused by Large Scale Forest Fires in Indonesia, 1997. *Unpublished report for the German Technical Cooperation (GTZ) project on Strengthening the Management Capacities of the Indonesian Forestry Ministry (SCMP) and the Integrated Forest Fire Management Project (IFFM). Jakarta*.

HOLLAND, J. H. 1992. *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control and Artificial Intelligence*, MIT Press.

JANG, J.-S. R. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics, Systems, Man and Cybernetics, IEEE Transactions on, IEEE Trans. Syst., Man, Cybern.,* 23**,** 665-685.

JERRETT, M., BURNETT, R. T., POPE, C. A., ITO, K., THURSTON, G., KREWSKI, D., SHI, Y., CALLE, E. & THUN, M. 2009. Long-Term Ozone Exposure and Mortality. *New England Journal of Medicine,* 360**,** 1085-1095.

KALIPSIZ, O. & CİHAN, P. 2016. Öğrenci Proje Anketlerini Sınıflandırmada En İyi Algoritmanın Belirlenmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 8, 41-49.

KARAL, Ö. & BÜYÜKBERBER, S. 2018. EKG verilerinin Destek Vektör Regresyon yöntemiyle sıkıştırılması / Compression of ECG data by Support Vector Regression method. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi,* 33**,** 713-724.

KHURANA, M. & SAXENA, V. 2021. Green cover change detection using a modified adaptive ensemble of extreme learning machines for North-Western India. *Journal of King Saud University-Computer and Information Sciences,* 33**,** 1265-1273.

KOSB 2022. *Kurumsal* [Online]. Kapaklı Organize Sanayi Bölge Müdürlüğü. https://www.kapakliosb.org.tr/kapakli-osb-kurumsal/8/kapakli-osb [Erişim tarihi: 21 Mart 2022].

KOTHARI, D. P., SINGAL, K. C. & RANJAN, R. 2016. *Environmental Science and Engineering*, Alpha Science International.

KUNT, F. 2014. *Bulanık mantık ve yapay sinir ağları yöntemleri kullanılarak Konya il merkezi hava kirliliği modellenmesi.* Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü.

KWON, S. J. 2011. *Artificial neural networks*, Nova Science Publishers.

LATIF, M. 2009. *Climate change: the point of no return*, Haus Publishing.

LEE, B.-J., KIM, B. & LEE, K. 2014. Air pollution exposure and cardiovascular disease. *Toxicological research,* 30**,** 71-75.

LI, M., CAI, W. & LIU, X. 2018. Improved Ensemble Extreme Learning Machine Regression Algorithm. *International Conference on Intelligent Information Processing***,** 12-19.

LI, T., JI, X. & LI, J. 2018. A Speed-up K-Nearest Neighbor Classification Algorithm for Trojan Detection. *International Conference on Advanced Hybrid Information Processing***,** 214-224.

LI, X., HUSSAIN, S. A., SOBRI, S. & MD SAID, M. S. 2021. Overviewing the air quality models on air pollution in Sichuan Basin, China. *Chemosphere,* 271**,** 129502.

LI, Y., JIANG, P., SHE, Q. & LIN, G. 2018. Research on air pollutant concentration prediction method based on self-adaptive neuro-fuzzy weighted extreme learning machine. *Environmental Pollution,* 241**,** 1115-1127.

LIAW, A. & WIENER, M. 2002. Classification and regression by randomForest. *R news,* 2**,** 18-22.

LIU, Z., GUAN, Q., LUO, H., WANG, N., PAN, N., YANG, L., XIAO, S. & LIN, J. 2019. Development of land use regression model and health risk assessment for NO_2 in different functional areas: A case study of Xi'an, China. *Atmospheric Environment,* 213**,** 515-525.

LOVEJOY, S. 2013. What is climate? *Eos, Transactions American Geophysical Union,* 94**,** 1-2.

LOVRIĆ, M., PAVLOVIĆ, K., VUKOVIĆ, M., GRANGE, S. K., HABERL, M. & KERN, R. 2021. Understanding the true effects of the COVID-19 lockdown on air pollution by means of machine learning. *Environmental Pollution,* 274.

MA, X. 2018. *Using classification and regression trees: A practical primer*, IAP.

MGM 2020a. Çerkezköy İstasyonu Meteoroloji Verileri. *T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Meteoroloji Genel Müdürlüğü*, MEVBİS.

MGM 2020b. Türkiye Yıllık Ortalama Sıcaklık Raporu. *T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü.*

MGM 2021a. *Meteorolojiye Giriş* [Online]. T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü. https://www.mgm.gov.tr/genel/meteorolojiyegir.aspx [Erişim tarihi: 29 Mayıs 2021].

MGM 2021b. *Tekirdağ İline Ait Genel İstatistiki veriler* [Online]. T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı, Meteoroloji Genel Müdürlüğü. https://mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=A&m=TEKIRDAG [Erişim tarihi: 1 Aralık 2021].

MGM 2021c. *Tekirdağ İline Ait Mevsim Normalleri* [Online]. T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı, Meteoroloji Genel Müdürlüğü. https://mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=H&m=TEKIRDAG [Erişim tarihi: 1 Aralık 2021].

MINES, J. & RICHARD, O. 2014. *Environmental engineering: principles and practice*, John Wiley & Sons.

MOYE, J. N. 2019. *A Machine Learning, Artificial Intelligence Approach to Institutional Effectiveness in Higher Education,* Bingley, UNITED KINGDOM, Emerald Publishing Limited.

MUTLU, E. A., COMBA, I. Y., CHO, T., ENGEN, P. A., YAZICI, C., SOBERANES, S., HAMANAKA, R. B., NIĞDELIOĞLU, R., MELITON, A. Y., GHIO, A. J., BUDINGER, G. R. S. & MUTLU, G. M. 2018. Inhalational exposure to particulate matter air pollution alters the composition of the gut microbiome. *Environmental Pollution,* 240**,** 817-830.

MÜEZZINOĞLU, A. 2000. *Hava Kirliliğinin Kontrolünün Esasları*, Dokuz Eylül Yayınları, İzmir.

NEWBY, D. E., MANNUCCI, P. M., TELL, G. S., BACCARELLI, A. A., BROOK, R. D., DONALDSON, K., FORASTIERE, F., FRANCHINI, M., FRANCO, O. H. & GRAHAM, I. 2015. Expert position paper on air pollution and cardiovascular disease. *European heart journal,* 36**,** 83-93.

NOAA 2011. Weather & Climate. *US Dept of Commerce* [Online]. https://www.weather.gov/media/owlie/2011_Weather_Climate_General_Public.pdf [Erişim tarihi: 6 Şubat 2022].

NORBÄCK, D., LU, C., ZHANG, Y., LI, B., ZHAO, Z., HUANG, C., ZHANG, X., QIAN, H., SUN, Y., WANG, J., LIU, W., SUNDELL, J. & DENG, Q. 2019. Sources of indoor particulate matter (PM) and outdoor air pollution in China in relation to asthma, wheeze, rhinitis and eczema among pre-school children: Synergistic effects between antibiotics use and PM_{10} and second hand smoke. *Environment International,* 125**,** 252-260.

OMAR, T. & PETER, C. F. 2017. *R Programming By Example: Practical, Hands-on Projects to Help You Get Started with R,* Birmingham, Packt Publishing.

ÖNGEN, A., ÖZCAN, H. K. & ARAYICI, S. 2013. An evaluation of tannery industry wastewater treatment sludge gasification by artificial neural network modeling. *Journal of hazardous materials,* 263**,** 361-366.

ÖZCAN, H. K., ŞAHIN, Ü., BAYAT, C. & UÇAN, O. N. 2013. İstanbul ili tropsoferik ozon (O_3) konsantrasyonlarının hücresel yapay sinir ağ yöntemiyle modellenmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi,* 21**,** 239.

ÖZCAN, N. S. 2016. *Kentsel hava kirliliğini etkileyen ve şehir planlama ile kontrol edilebilen fiziksel faktörlerin mekânsal istatistik yöntemleri ile incelenmesi.* Doktora Tezi.

ÖZTÜRK, H. K., CEYLAN, H., CANYURT, O. E. & HEPBAŞLI, A. 2005. Electricity estimation using genetic algorithm approach: a case study of Turkey. *Energy,* 30**,** 1003-1012.

POLEZER, G., TADANO, Y. S., SIQUEIRA, H. V., GODOI, A. F. L., YAMAMOTO, C. I., DE ANDRÉ, P. A., PAULIQUEVIS, T., ANDRADE, M. D. F., OLIVEIRA, A., SALDIVA, P. H. N., TAYLOR, P. E. & GODOI, R. H. M. 2018. Assessing the impact of $PM_{2.5}$ on respiratory disease using artificial neural networks. *Environmental Pollution,* 235**,** 394-403.

RAI, P. K. 2016. Biodiversity of roadside plants and their response to air pollution in an Indo-Burma hotspot region: implications for urban ecosystem restoration. *Journal of Asia-Pacific Biodiversity,* 9**,** 47-55.

REN, K. 2016. *Learning R Programming,* Birmingham, Packt Publishing.

SAYLI, A., AKBULUT, C. & KOSUTA, K. 2018. Multiple Regression Analysis System in Machine Learning and Estimating Effects of Data Transformation&Min-Max Normalization. *Journal of Engineering Technology and Applied Sciences,* 3**,** 189.

SCHNELLE JR, K. B., DUNN, R. F. & TERNES, M. E. 2015. *Air pollution control technology handbook*, CRC press.

SHALEV-SHWARTZ, S. & BEN-DAVID, S. 2014. *Understanding machine learning: From theory to algorithms*, Cambridge university press.

SİM 2020. *Ulusal Hava Kalitesi İzleme Ağı* [Online]. T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Sürekli İzleme Merkezi. https://sim.csb.gov.tr/Services/AirQuality [Erişim tarihi: 5 Haziran 2020].

SMOLA, A. J. & SCHÖLKOPF, B. 2004. A tutorial on support vector regression. *Statistics and computing,* 14**,** 199-222.

SPELLMAN, F. R. 2012. *The handbook of Meteorology*, Scarecrow Press.

SRIVASTAVA, C., SINGH, S. & SINGH, A. P. Estimation of air pollution in Delhi using machine learning techniques. 2018 International Conference on Computing, Power and Communication Technologies (GUCON), 2018. IEEE, 304-309.

TAYLOR, K. E. 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres,* 106**,** 7183-7192.

TEMAM, S., BURTE, E., ADAM, M., ANTÓ, J. M., BASAGAÑA, X., BOUSQUET, J., CARSIN, A.-E., GALOBARDES, B., KEIDEL, D., KÜNZLI, N., LE MOUAL, N., SANCHEZ, M., SUNYER, J., BONO, R., BRUNEKREEF, B., HEINRICH, J., DE HOOGH, K., JARVIS, D., MARCON, A., MODIG, L., NADIF, R., NIEUWENHUIJSEN, M., PIN, I., SIROUX, V., STEMPFELET, M., TSAI, M.-Y., PROBST-HENSCH, N. & JACQUEMIN, B. 2017. Socioeconomic position and outdoor nitrogen dioxide (NO_2) exposure in Western Europe: A multi-city analysis. *Environment International,* 101**,** 117-124.

TUNGUT, H. B. 2019. *Algoritma ve programlama mantığı,* [N.p.], KODLAB Yayın Dağıtım.

TÜİK 2021. *Adrese Dayalı Nüfus Kayıt Veri Tabanı* [Online]. Türkiye İstatistik Kurumu. https://biruni.tuik.gov.tr/medas/?locale=tr [Erişim tarihi: 31 Mart 2022].

UHKİA 2020. *Hava kalitesi indeksi* [Online]. T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Ulusal Hava Kalitesi İzleme Ağı. https://sim.csb.gov.tr/Home/HKI?baslik=HAVZA%20İZLEME%20SİSTEMİ [Erişim tarihi: 6 Haziran 2020].

VALLERO, D. A. 2008. 1 - The Changing Face of Air Pollution. *In:* VALLERO, D. A. (ed.) *Fundamentals of Air Pollution (Fourth Edition).* Burlington: Academic Press.

VAPNIK, V. 1999. *The nature of statistical learning theory*, Springer science & business media.

VONG, C.-M., IP, W.-F., WONG, P.-K. & CHIU, C.-C. 2014. Predicting minority class for suspended particulate matters level by extreme learning machine. *Neurocomputing,* 128**,** 136-144.

WANG, P., CHANG, J. & ZHANG, L. 2018. *Artificially Intelligent Nanomaterials for Environmental Engineering*.

WAP 2020. *Real-time Air Quality Index* [Online]. World's Air Pollution. https://waqi.info/ [Erişim tarihi: 1 Haziran 2020].

WHITEMAN, C. D. 2000. *Mountain meteorology: fundamentals and applications*, Oxford University Press.

WILLMOTT, C. J. & MATSUURA, K. 2005. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate research,* 30**,** 79-82.

YALÇIN, G., DEMIRCAN, M., ULUPINAR, Y. & BULUT, E. 2005. Klimatoloji - I. *DMİ Yayınları*.

YAVUZ, H. S., CETIŞLI, B. & ATMACA, H. The Comparison of Fuzzy Inference Systems and Neural Network Approaches with ANFIS Method for Fuel Consumption Data. 2001.

YOO, J., SHIN, D. & SHIN, D. 2019. Prediction System for Fine Particulate Matter Concentration Index by Meteorological and Air Pollution Material Factors Based on Machine Learning. 479-485.

YUN, Y., GAO, R., YUE, H., LI, G., ZHU, N. & SANG, N. 2015. Synergistic effects of particulate matter (PM_{10}) and SO_2 on human non-small cell lung cancer A549 via ROS-mediated NF-κB activation. *Journal of Environmental Sciences,* 31**,** 146-153.

YÜKSEL, H., ÇALIŞKAN, F. & DAYIK, M. 2016. Genetik algoritmaların tasarım sürecinde kullanılması. *Teknik Bilimler Dergisi,* 6.

ZHAI, B. & CHEN, J. 2018. Development of a stacked ensemble model for forecasting and analyzing daily average $PM_{2.5}$ concentrations in Beijing, China. *Science of the Total Environment,* 635**,** 644-658.

ZHANG, J. & DING, W. 2017. Prediction of air pollutants concentration based on an extreme learning machine: The case of Hong Kong. *International Journal of Environmental Research and Public Health,* 14.

ZOHURI, B. & MOGHADDAM, M. 2017. *Neural Network Driven Artificial Intelligence: Decision Making Based on Fuzzy Logic*, Nova Science Publishers Incorporated

İNTİHAL RAPORU İLK SAYFASI

Hüseyin Özel_

ORİJİNALLİK RAPORU

%16	%15	%3	%5
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	acikerisim.kirklareli.edu.tr İnternet Kaynağı	%4
2	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%1
3	tekirdag.tarimorman.gov.tr İnternet Kaynağı	%1
4	acikbilim.yok.gov.tr İnternet Kaynağı	%1
5	mgm.gov.tr İnternet Kaynağı	%1
6	issuu.com İnternet Kaynağı	%1
7	webdosya.csb.gov.tr İnternet Kaynağı	<%1
8	Submitted to Kirikkale University Öğrenci Ödevi	<%1
9	www.acarindex.com İnternet Kaynağı	<%1