



T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI

PM₁₀ PARAMETRESİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE
MEKÂNSAL ANALİZİ, KAYSERİ İLİ ÖRNEĞİ

NURAY ŞAŞA

Şubat 2021

T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI

PM₁₀ PARAMETRESİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE
MEKÂNSAL ANALİZİ, KAYSERİ İLİ ÖRNEĞİ

NURAY ŞAŞA

Yüksek Lisans Tezi

Danışman

Dr. Öğr. Üyesi Öznur Begüm Gökçek

İkinci Danışman

Dr. Öğr. Üyesi Yeşim DOKUZ

Şubat 2021

Nuray ŞAŞA tarafından Dr. Öğretim Üyesi Öznur Begüm GÖKÇEK ve ikinci danışman Dr. Öğretim Üyesi Yeşim DOKUZ danışmanlıklarında hazırlanan “PM₁₀ Parametresinin Makine Öğrenmesi Algoritmaları ile Mekânsal Analizi, Kayseri İl Örneği” adlı bu çalışma jürimiz tarafından Niğde Ömer Halisdemir Üniversitesi Fen Bilimleri Enstitüsü **Çevre Mühendisliği** Ana Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Fehiman ÇİNER (Niğde Ömer Halisdemir Üniversitesi)

Üye : Dr. Öğr. Üyesi İlknur ŞENTÜRK (Sivas Cumhuriyet Üniversitesi)

Üye : Dr. Öğr. Üyesi Ela ERTUNÇ (Konya Teknik Üniversitesi)

Üye : Dr. Öğr. Üyesi Öznur Begüm GÖKÇEK (Niğde Ömer Halisdemir Üniversitesi)

Üye : Dr. Öğr. Üyesi Yeşim DOKUZ (Niğde Ömer Halisdemir Üniversitesi)

ONAY:

Bu tez, Fen Bilimleri Enstitüsü Yönetim Kurulunca belirlenmiş olan yukarıdaki jüri üyeleri tarafından/...../20.... tarihinde uygun görülmüş ve Enstitü Yönetim Kurulu’nun/...../20.... tarih ve sayılı kararıyla kabul edilmiştir.

...../...../20...

Prof. Dr. Murat BARUT
MÜDÜR

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin bilimsel ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Nuray ŞAŞA



ÖZET

PM₁₀ PARAMETRESİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE MEKÂNSAL ANALİZİ, KAYSERİ İLİ ÖRNEĞİ

ŞAŞA, Nuray

Niğde Ömer Halisdemir Üniversitesi

Fen Bilimleri Enstitüsü

Çevre Mühendisliği Anabilim Dalı

Danışman : Dr. Öğr. Üyesi Öznur Begüm GÖKÇEK
İkinci Danışman : Dr. Öğr. Üyesi Yeşim DOKUZ

Şubat 2021, 71 Sayfa

Hava kirliliğinin son yıllarda artışı ile birlikte alınacak olan erken önlemler dâhilinde hava kirliliği tahmininin yapılması insan ve çevre sağlığına verilebilecek zararın en aza indirilmesinde önemlidir. Bu çalışmada günlük ortalama hava kirliliği miktarının, önemli bir hava kirletici olan PM₁₀ konsantrasyonu üzerinden tahminlenmesi ve hava kirliliğinin çevresel ve mekânsal modellenmesi amaçlanmıştır. Tahminleme modeli, Orta Anadolu Bölgesinde yer alan Kayseri ilinde bulunan 3 istasyondan alınan 2010-2018 yılları arasında ölçülen PM₁₀ (partikül madde) konsantrasyonu verileri kullanılarak makine öğrenmesi algoritmaları (kNN SVR, RF, ANN, Lineer Regresyon) ile eğitilmiştir. Kayseri'deki 3 istasyonun 2010-2018 yılları arasındaki PM₁₀ konsantrasyon değerleri girdi olarak verilmiş ve 2019 yılına ait PM₁₀ konsantrasyon değerleri tahmin edilmiştir. En iyi sonuçlar 3 istasyon için de SVR algoritması ile elde edilmiş olup Trafik bölgesi için R²:0.85, RMSE:17.57, MAE:10.17; Hürriyet bölgesi için R²:0.73, RMSE:34.91, MAE:24.61 ve OSB bölgesi için R²:0.82, RMSE:41.71, MAE:21.62 olduğu tespit edilmiştir. Tahmini konsantrasyon sonuçlarının mekânsal dağılımı (CBS) ile sağlanarak, hava kirliliğinin iyileştirilmesine yönelik stratejiler oluşturulmuştur.

Anahtar Kelimeler: Makine öğrenmesi algoritmaları, PM10, destek vektör algoritması, CBS, mekânsal analiz

SUMMARY

SPATIAL ANALYSIS OF PM10 PARAMETER BY MACHINE LEARNING ALGORITHMS, CITY OF KAYSER

ŞAŞA, Nuray

Niğde Ömer Halisdemir University

Graduate School of Natural and Applied Sciences

Department of Environmental Engineering

Supervisor : Assistant Professor Dr. Öznur Begüm GÖKÇEK

Co-Advisor : Assistant Professor Dr. Yeşim DOKUZ

Şubat 2021, 71 pages

With the increase of air pollution in recent years, it is important to make an estimation of air pollution within the scope of early measures to be taken in minimizing the damage to human and environmental health. In this study, it is aimed to estimate the daily average amount of air pollution from the PM10 concentration, which is an important air pollutant, and to model the environmental and spatial air pollution. The prediction model was trained with machine learning algorithms (kNN SVR, RF, ANN, Linear Regression) using PM10 (particulate matter) concentration data measured between 2010-2018 from 3 stations in Kayseri, Central Anatolia. PM10 concentration values of 3 stations in Kayseri between 2010-2018 were given as input and PM10 concentration values for 2019 were estimated. The best results were obtained with SVR algorithm for all three stations. For the traffic zone, R2: 0.85, RMSE: 17.57, MAE: 10.17; For Hürriyet region, R2: 0.73, RMSE: 34.91, MAE: 24.61 and for OSB region R2: 0.82, RMSE: 41.71, MAE: 21.62. The spatial distribution of the estimated concentration results obtained was provided by the Geographical Information System (GIS), and spatial strategies were created to improve air pollution on land use.

Keywords: Machine learning algorithms, PM10, Support vector algorithm, GIS, spatial analysis

ÖN SÖZ

Özellikle büyük şehirlerdeki hava kirliliği çevre koşulları üzerinde oldukça etkilidir. Kirlilik risklerine karşı korunmak ve tedbir alabilmek için geliştirilen hava kirliliği kontrol teknolojilerinin varlığı hava kirliliğinin doğru tahminine bağlıdır. Bu tez çalışmasında hava kirliliğini belirlemek için gösterge kirleticilerden PM_{10} 'dan faydalanılmıştır. PM_{10} parametresi makine öğrenmesi algoritmaları kullanılarak tahminleme yapılmış ve hava kirliliğinin çevresel ve mekânsal modellenmesi amaçlanmıştır. Tahminleme modelinde, Kayseri'deki 3 istasyonun 2010-2018 yılları arasındaki PM_{10} konsantrasyon değerleri girdi olarak verilmiş ve 2019 yılına ait PM_{10} konsantrasyon değerleri tahmin edilmiştir. Elde edilen tahmini konsantrasyon sonuçlarının mekânsal analizi CBS ile sağlanarak arazi kullanım üzerinde hava kirliliğinin iyileştirilmesine yönelik mekânsal stratejiler oluşturulmuştur.

Tez çalışmam boyunca her türlü destek ve yardımını esirgemeyen danışman hocalarım Sayın Dr. Öğretim Üyesi Öznur Begüm GÖKÇEK, Bilgisayar Mühendisliği Sayın Dr. Öğretim Üyesi Yeşim DOKUZ ve bilgi birikiminden yararlandığım desteğini esirgemeyen hocam Harita Mühendisliği Sayın Dr. Öğretim Üyesi Aslı BOZDAĞ'a sonsuz teşekkürlerimi sunarım. Bu tezi, maddi ve manevi desteğini esirgemeyen değerli eşim Selim ŞAŞA'ya ithaf ediyorum.

İÇİNDEKİLER

ÖZET	iv
SUMMARY.....	v
ÖN SÖZ	vi
İÇİNDEKİLER.....	vii
ÇİZELGELER DİZİNİ.....	x
ŞEKİLLER DİZİNİ	xi
SİMGE VE KISALTMALAR.....	xii
BÖLÜM I GİRİŞ	1
1.1 Çalışmanın Kapsam ve Amacı	1
BÖLÜM II HAVA KİRLİTİCİLER VE HAVA KALİTESİ.....	2
2.1 Hava Kirliliğinin Tanımı	2
2.2 Atmosferik Kirleticiler	4
2.2.1 Partikül madde (PM).....	4
2.2.2 Kükürt dioksit (SO ₂)	5
2.2.3 Azot oksitler (NO _x), azot dioksit (NO ₂), azot monoksit (NO)	6
2.2.4 Karbon monoksit (CO).....	6
2.2.5 Ozon (O ₃)	6
2.3 Hava Kirliliğine Etki Eden Faktörler.....	7
2.3.1 Meteorolojik faktörler	7
2.3.2 Atmosferik faktörler (inversiyon)	9
2.3.3 Topoğrafik faktörler	9
2.3.4 Kentleşme.....	9
2.3.5 Sanayileşme	10
2.3.6 Sosyo-ekonomik yapı.....	10
2.4 Hava Kirliliğinin Etkileri.....	10
2.4.1 İnsan sağlığı üzerine etkileri	11
2.4.2 Ekosistem üzerine etkileri	12
2.4.3 İklim değişikliği üzerine etkileri	13
2.4.4 Kültürel miras ve yapılar üzerine etkileri	13
2.4.5 Ekonomik etkiler	13

2.5 Dünyada ve Türkiye’de Hava Kirliliği	14
2.6 Hava Kalitesi Kavramı ve Modellemesi.....	19
BÖLÜM III MAKİNE ÖĞRENMESİ	27
3.1 Makine Öğrenmesi Kavramı ve Adımları	27
3.2 Makine Öğrenmesi Algoritmaları.....	28
3.2.1 Karar ağaçları	28
3.2.2 Torbalama	29
3.2.3 Rastgele orman.....	29
3.2.4 Artırma	30
3.2.5 Gradyan artırma	30
3.2.6 Ekstrem gradyan artırma.....	30
3.2.7 Light gradyan artırma.....	31
3.2.8 Ekstra rastgele orman.....	31
3.2.9 Adaboost	31
3.2.10 Düzenlileştirme	32
3.2.10.1 Çıkıntı.....	32
3.2.10.2 Lasso	32
3.2.10.3 Elastic net.....	32
3.2.11 Basit bayes sınıflandırıcı.....	32
3.2.12 K-en yakın komşu	33
3.2.13 Destek vektör makineleri (SVR).....	33
3.2.14 Lineer regresyon	34
3.2.15 Yapay sinir ağları (ANN).....	34
3.3 Performans Metrikleri.....	34
3.4 Literatür Özeti.....	35
BÖLÜM IV MATERYAL VE YÖNTEM.....	38
4.1 Çalışma Bölgesi ve Hava Kirliliği Verileri	38
4.1.1 Coğrafi konumu	38
4.1.2 Kent nüfusu	39
4.1.3 İklim özellikleri.....	40
4.1.4 Hava kalitesi.....	41
4.2 Örnekleme Noktaları ve Örnekleme Analizleri.....	43
4.3 Mekansal Analiz	43
BÖLÜM V BULGULAR VE TARTIŞMA	45

5.1 Makine Öğrenmesi Algoritmaları.....	45
5.2 Mekansal Analiz Sonuçları.....	56
BÖLÜM VI SONUÇLAR.....	61
KAYNAKLAR.....	63
ÖZ GEÇMİŞ.....	71



ÇİZELGELER DİZİNİ

Çizelge 2.1. Hava kirletici parametrelerin ana kaynağı ve sağlık üzerine etkileri	12
Çizelge 2.2. Türkiye Hava Kalitesini Kontrol Yönetmeliği'ne (THKKY) göre belirlenen kısa ve uzun dönem sınır değerler ile DSÖ ve AB hava kalite değerleri	17
Çizelge 2.3. SO ₂ ,NO ₂ , NO _x ve PM ₁₀ için sınır değerler	20
Çizelge 2.4. Hava kirliliği izleme teknikleri.....	23
Çizelge 4.1. 2007-2019 yıllarına göre Kayseri nüfusu	40
Çizelge 4.2. Kayseri ilinin aylık ortalama sıcaklık ve yağış değerleri	40
Çizelge 4.3. Ulusal Hava Kalite İndeksi kesme noktaları	41
Çizelge 4.4. Kayseri’de 2019 yılı hava kalitesi ölçüm istasyon yerleri ve ölçülen parametreler	42
Çizelge 5.1. Makine öğrenmesi algoritmalarıyla PM ₁₀ konsantrasyon tahmini deney sonuçları	46
Çizelge 5.2. 2018-2020 yılları Mart-Nisan-Mayıs ve Haziran aylarına ilişkin PM ₁₀ değerleri.....	56
Çizelge 5.3. İstasyonların çevresindeki mahallelerin nüfus yoğunluğu değişimi.....	58

ŞEKİLLER DİZİNİ

Şekil 2.1. Havanın yapısı	2
Şekil 2.2. Atmosferi oluşturan tabakalar	3
Şekil 2.3. Hava kirliliğinin oluşturduğu ekonomik maliyet.....	11
Şekil 2.4. Dünya’da 2010’dan 2016 yılına doğru hava kirlilik değişimi.....	15
Şekil 2.5. Dünya Sağlık Örgütü’nün sınır değerlerine göre Türkiye’nin PM kirliliği....	16
Şekil 2.6. Karantina sonucu hava kirliliği oranındaki azalma yüzdesi	18
Şekil 2.7. İtalya’nın Şubat ve Mart ayı hava kirliliği uydu görüntüsü.....	19
Şekil 3.1. Makine öğrenmesi yöntemleri	28
Şekil 4.1. Kayseri kenti genel görünümü.....	38
Şekil 4.2. Kayseri Hava Kalite İndeksi	42
Şekil 5.1. Algoritmalar sonucu ile gerçek değerlerin yıllık olarak karşılaştırılması	47
Şekil 5.2. Hürriyet-Trafik ve OSB istasyonlarına ait 2010-2019 yılları arası PM ₁₀ konsantrasyonu aylık değişimi.....	50
Şekil 5.3. Hürriyet-Trafik ve OSB istasyonlarına ait 2010-2019 yılları arası PM ₁₀ konsantrasyonu değişimi.....	53
Şekil 5.4. Kayseri kent merkezinin yıllara göre mevcut durum analizi.....	57
Şekil 5.5. 2010, 2015 ve 2019 yıllarına göre PM ₁₀ hava kalitesi değişiminin mekânsal dağılımı	59

SİMGE VE KISALTMALAR

Simgeler

Açıklama

NO _x	: Azot oksitler
SO _x	: Kükürt oksitler
SO ₂	: Kükürt dioksit
NO	: Azot monoksit
NO ₂	: Azot dioksit
CO	: Karbon monoksit
O ₃	: Ozon
HC	: Hidrokarbon

Kısaltmalar

Açıklama

PM	: Partikül Madde
AÇA	: Avrupa Çevre Ajansı
DSÖ	: Dünya Sağlık Örgütü
THKKY	: Türkiye Hava Kalitesini Kontrol Yönetmeliği
HKİ	: Hava Kalite İndeksi
TÜİK	: Türkiye İstatistik Kurumu
ÇED	: Çevre Etki Değerlendirme
HKDY	: Hava Kalitesi Değerlendirme ve Yönetimi
OSB	: Organize Sanayi Bölgesi
LR	: Doğrusal Regresyon Algoritması
RF	: Rastgele Orman Algoritması
YSA	: Yapay Sinir Ağları Algoritması
kNN	: k En Yakın Komşu Algoritması
MAE	: Ortalama Mutlak Hata
RMSE	: Kök Ortalama Kare Hatası
R ²	: Doğruluk Oranı

BÖLÜM I

GİRİŞ

1.1 Çalışmanın Kapsam ve Amacı

Son yıllarda gelişen sanayi, şehirleşme oranındaki artış ve ulaşımın gelişmesi ile artan hava kirliliği her geçen gün insan ve canlı yaşamını tehdit eder boyuta ulaşmaktadır. Doğal olarak havada yer almayan kirleticilerin ortaya çıkması ya da zararlı boyutlarda olmayan kirletici partiküllerin havadaki miktarındaki artışı hava kirliliğini oluşturmaktadır. En önemli hava kirletici parametreleri, Partikül Madde (PM), Kükürt dioksit (SO₂), Karbon monoksit (CO), Karbondioksit (CO₂), Ozon (O₃), Azotoksitler (NO_x) ve Hidrokarbonlar (HC)'dir. Kirleticilerin kaynağı yangın, toz taşınımı gibi doğal kaynaklar olacağı gibi antropojenik faaliyetlerden olan fabrika, enerji tesisi, yakma tesisi ve inşaat kaynaklı da olabilmektedir.

Hava kirliliğinin özellikle insan sağlığı üzerindeki etkisinden dolayı kirliliğin belirlenmesi, kirletici düzeylerinin kontrol altında tutulması ve önlenmesi adına pek çok çalışma yapılmaktadır. Hava kalitesi izleme çalışması bunlardan biridir. Bu izlemin devamlı gerçekleşmesi için belirli noktalarda izleme istasyonları kurulmuştur. Ancak bu istasyonların kurulum ve işletme maliyetleri yüksek olduğundan sınırlı sayıda bulunmaktadır. Bu durumda kişilerin hava kirliliğine gerçek maruz kalım düzeyleri saptanamamaktadır. Hava kalitesini değerlendirmek için farklı yöntemler kullanılsa da son yıllarda en yaygın kullanılan hava kalite modellemesi yapay sinir ağları ile tahminleme sistemidir. Bu sistem geliştirilen bilgisayar programları ile hava kirletici dağılımının matematiksel olarak tahmininin yapılması işlemine dayanır.

Bu tezde, Kayseri ili için belirlenen üç istasyondan 2010-2018 PM₁₀ konsantrasyon verileri alınarak 2019 yılı için makine öğrenmesi algoritmaları (SVM, RF, kNN, ANN) kullanılarak en doğru tahminlemenin yapılması, bu tahmin değerlerine göre mekânsal dağılımın CBS yardımıyla analizinin yapılması ve hava kirliliğinin iyileştirilmesine yönelik önlemlerin alınması amaçlanmıştır. Bu üç istasyon için Trafik, Hürriyet ve OSB bölgeleri seçilmiştir. PM₁₀ konsantrasyon verileri Hava İzleme Ağından temin edilmiştir.

BÖLÜM II

HAVA KİRLLETİCİLER VE HAVA KALİTESİ

2.1 Hava Kirliliğinin Tanımı

Hava, Dünya'nın etrafını çevreleyen, büyük bir kısmı azot ve oksijenden oluşan gaz kütlesi olarak tanımlanmaktadır. Hava, renksiz ve kokusuz olup tüm canlılar için hayati önem taşımaktadır. Bir insan yaklaşık olarak günde 2,5 lt. su, 1,5 kg besin ve 10 - 20 m³ hava gereksinimine ihtiyaç duymaktadır. İnsan açlığa 60 gün, susuzluğa 6 gün dayanabilirken havasızlığa ancak 6 dakika dayanabilmektedir (URL-1, 2019).


Atmosfer, yeryüzünü saran, güneşten gelen enerjinin uzaya geri dönmesini önleyen hava kütlesine denir. Bir gaz karışımı olan havanın, kuru hacim olarak içeriğinde Şekil 2.1'de gösterildiği gibi %78.1 azot, %20.9 oksijen, %0.9 argon, % 0.04 karbon dioksit, %0.002 neon, % 0.0005 helyum ve diğerleri mevcuttur. Ancak böyle bir hava doğada bulunmamaktadır (Vesilind vd., 2011).



Şekil 2.1. Havanın yapısı

Atmosfer birbirinden farklı sıcaklık ve kimyasal özelliklere sahip tabakalardan oluşmaktadır. Atmosferi oluşturan tabakalar Şekil 2.2'de mevcuttur. Havamızın

çoğunun bulunduğu Troposfer, ekvator ve kutuplarda değişkenlik gösteren ve yüksekliği de yaklaşık 10 km olan ilk katmandır.



Şekil 2.2. Atmosferi oluşturan tabakalar

Hava kirliliği, atmosferde bulunan gaz, toz ve koku şeklinde bulunan kirleticilerin, insan, canlı ve çevre üzerinde olumsuz etki bırakacak seviyeye gelmesi şeklinde tanımlanmaktadır. İnsanların çeşitli faaliyetleri sonucu hava tabakası kirlenerek, yeryüzündeki canlı yaşamı olumsuz etkilenmektedir. Hava kirliliğine neden olan kirleticilerin sınır değerleri, ülkelerin bu konu ile ilgilenen ilgili kuruluşları tarafından yönetmeliklerle belirlenir (URL-2, 2019).

Kirletici maddelerin yapılarına göre, canlılar üzerindeki etkisi de değişkenlik gösterir. Kirliliğin kaynağına (fabrika, termik santral, konutlar, taşıt araçları) göre alınabilecek önlemler de değişmektedir. Hava kalitesi parametreleri düzenli ve sistemli olarak ölçülürse, bölgedeki kirlilik düzeyini belirlemek daha kolay olabilmektedir (Tosun, 2017). İnsanlar çok uzun yıllardır oluşan hava kirlenmesinin farkındadırlar. 1273'de İngiltere Kralının Londra'da yumuşak kömürün kullanılması için Parlamentoyu ikna etmesi ile hava kirliliğinin kontrol edilmesine yönelik ilk kanun çıkarılmıştır. 1905 yılında ilk defa bir doktor tarafından "Dumanlı-Sis" terimi açıklanmış, bu terimin duman ve sis karışımı sonucu ortaya çıktığı ve hava kalitesini kötü etkilediği belirtilmiştir. 17. yy. da ilk asit yağmuru tanımlanırken, 18. yy. da asit yağmuru ve

dumanlı-sisin Londra'da bulunan bitkiler üzerinde bazı olumsuzluklara neden olduđu belirlenmiştir. Sanayi devriminin başlamasıyla, hava kirliliđi daha belirgin hale gelmiştir.

2.2 Atmosferik Kirleticiler

Atmosfer, dünyamızı saran ve deđişken yoğunluklardaki gazlardan oluşan bir gaz kütesidir. Hava, yüksekliğe bađlı olarak yoğunluk farkına ve kimyasal bileşim farklılıklarına sahiptir. Hava, meteorolojik faaliyetler ile içerdіđi toz, kirletici, partikül vb. taşınımına neden olmaktadır.

Sıklıkla karşılaştığımız hava kirleticileri:

- Azot oksitler (NO_x)
- Kükürt Oksitler (SO_x)
- Karbon monoksit (CO)
- Ozon (O₃)
- Partiküller

Bu kirleticilerin bazıları doğrudan kirletici kaynaktan atılarak bazıları da atmosferdeki reaksiyon geçirmeleri sonucunda oluşan atıklar olarak havada bulunurlar. Bunlardan ilk ifade edilen birincil kirleticilerdir (CO, CO₂, SO₂, NO, HC, toprak kökenli partiküller vb.). Diğer kısmı da ikincil kirleticilerdir (O₃, NO, NO₂, NO₃, HNO₃ vb.) (Müezzinođlu, 2000).

Havanın içinde farklı oranlarda kimyasalların bulunması ve belli oranın üzerine çıkması canlı üzerinde sorun oluşturur. Bu nedenle hava kirletici parametrelerinin izlenmesi ve takip edilmesini gerektirmektedir.

2.2.1 Partikül madde (PM)

Partikül maddeler aerodinamik çaplarına göre adlandırılmaktadır. 10 µm'den küçük aerodinamik çapları olan partiküller PM₁₀, 2,5 µm'den küçük aerodinamik çaplara sahip

partiküller $PM_{2,5}$ olarak adlandırılmaktadır. İriliklerine ve kimyasal yapılarına bağlı olarak havada yüzer halde bulunan bu tanecikler toz, buhar, sis, duman, sprej gibi isimler alır. Havanın partikül maddelerle veya doğal maddelerle dolu olması bazı olumsuzluklara neden olmaktadır. Bunlar;

- Görüş mesafesini kısaltıcı.
- Güneş ışınlarının enerji akışını değiştirici,
- İnsan ve canlı sağlığına olumsuz etki yapar.

Kirlilik kaynağının özelliğine göre partikül maddenin kirletici payları değişiklik gösterebilmektedir. Avrupa Çevre Ajansı (AÇA)'na göre kirletici kaynağına göre sıralama yapıldığında en büyük paya sahip %53 ile evsel ısınma, %17 endüstriyel faaliyetler ve %12 ulaşım kaynaklı olduğu görülmektedir (Tosun, 2017).

Ülkemizdeki en önemli kirletici (sınır değerleri aşan) PM_{10} ve $PM_{2,5}$ 'dur. Özellikle partikül maddeler (PM_{10} ve $PM_{2,5}$) ağır metaller (civa, kurşun, kadmiyum gibi) içermekte ve bununla beraber sağlık açısından önemli tehdit oluşturmaktadır.

2.2.2 Kükürt dioksit (SO_2)

SO_2 havada karmaşık reaksiyonlarla oksitlenerek SO_3 'e dönüşür ve ıslak ya da kuru çökelmeyle atmosferden ayrılan sülfatları (SO_x) oluşturur. Havadaki SO_x içerisinde en büyük pay SO_2 gazına aittir. Renksizdir ancak havada bulunan miktara (0.3-1 ppm) bağlı olarak ağızda karakteristik tat bırakır ve boğucu hisse yol açar. Kükürtlü gazlar insan sağlığı üzerinde olumsuz etki yapar. Özellikle akciğer yetmezliği ve solunum sistemi hastaları için öldürücü etki bırakabilir (Müezzinoğlu,2000).

Kükürtlü gazların etkisiyle asit yağışları meydana gelmektedir. Yapılan çalışmalar asit yağışlarının %70'inin kükürt dioksit; kalanının ise NO_x gazlarından oluştuğunu göstermiştir (Müezzinoğlu, 2000). Asit yağışlarının iki dolaylı olumsuz etkisi vardır. Birincisi asit yağışların yüzeyel akış sonrası ulaştıkları alıcı su ortamında dengeyi bozmasıdır. İkincisi ise asidik yağışlar sonucu toprağın yıkanması ile besin maddeleri topraktan gider ve bu durum bitki örtüsünü olumsuz etkiler.

2.2.3 Azot oksitler (NO_x), azot dioksit (NO_2), azot monoksit (NO)

Kükürt oksitler gibi azot oksitler de birincil kirleticilerdendir. Azotun bazı oksitleri doğal (NO) bazı oksitleri ise insan faaliyetleri sonucu (NO_2) oluşmaktadır. NO renksiz, kokusuz ve zararsızdır. Fakat oksitlendiğinde kokulu ve zararlı bir gaz haline gelmektedir. Son zamanlarda evsel ısınma ve endüstriyel faaliyetler için kömür kullanımının azaltılarak doğalgaz kullanımına geçiş ile azot bileşiklerinin yüksek seyrettiğini göstermektedir.

Kirlilik kaynağının özelliğine göre NO_x kirletici payları değişiklik gösterebilmektedir. Avrupa Çevre Ajansı'na göre kirletici kaynağına göre sıralama yapıldığında en büyük paya sahip %39 ulaşım, %18 elektrik ve ısı üretimi, %15 endüstriyel faaliyetler olmaktadır (Tosun, 2017).

2.2.4 Karbon monoksit (CO)

Varlığı fark edilemeyen, renksiz, kokusuz, tatsız, havanın ortalama mol ağırlığına yakın ve karbon içeren yakıtların yanmasıyla ortaya çıkan bir gaz karbon monoksit olarak tanımlanmaktadır. Tam olmayan bir yanma sonucu birincil hava kirleticilerden (CO , CO_2 , SO_2 , NO , HC , toprak kökenli partiküller vb.) CO_2 yerine meydana gelmektedir. Havada bulunan karbon monoksitin insan sağlığı üzerinde gaz zehirlenmeleri (tam yanmamış atık gazların solunması) gibi önemli etkileri bulunmaktadır. Ayrıca kapalı mekânlardaki sigara dumanı ve taşıtların egzoz gazı karbon monoksitin iki önemli kaynağıdır. 2016 yılı Avrupa'nın Hava Kalitesi Raporu'na göre 746 istasyonda yapılan ölçüm sonuçlarına göre, trafiğin kente yakın ve yoğun olduğu saatlerde, büyük sanayi bölgelerinde CO parametresinin yüksek olduğu belirlenirken, 2000-2014 yılları arasında yapılan düzenlemeler ve denetimler ile birlikte CO maruziyetinin %45 azaltıldığı belirtilmektedir (Tosun, 2017).

2.2.5 Ozon (O_3)

Ozon, yaklaşık %90 oranında atmosferde troposfer ve stratosfer tabakalarında bulunmaktadır. Stratosfer tabakasında bulunan ozon, güneşten gelen ultraviyole ışınlarını tutması nedeniyle önemlidir. Troposfer tabakasında bulunan ozon ise toplam

ozonun %10'u olup insan kaynaklı olmaktadır. Ozonu aktif oksijen atomları oluşturur. Bu atomlar atmosferdeki çeşitli anorganik ve organik kimyasal kirleticileri oksitleyerek tüketir. Hava kirliliğine yol açan kaynaklar temel özelliklerine bakılarak iki ana grupta değerlendirilmektedir.

- Doğal Hava Kirliliği Kaynakları: Doğada kendiliğinden meydana gelen bazı olaylar havayı kirleten maddelerin ortaya çıkmasına neden olmaktadır. Bu şekilde ortaya çıkan kirletici maddeler atmosferde uzun süre kalmazlar. Bu olaylar;
 - a. Volkanik faaliyetler,
 - b. Tozlar,
 - c. Orman yangınları,
 - d. Okyanus spreyleri,
 - e. Çöl tozları.
- Antropojenik Hava Kirliliği Kaynakları: İnsan faaliyetleri sonucu ortaya çıkan kirliliktir. Suni kaynaklardan meydana gelen kirliliktir. Çünkü kirliliğin atmosferdeki salınım süresi oldukça uzun ve tehlikelidir. Bu kaynaklar;
 - a. Motorlu araç,
 - b. Endüstri,
 - c. Enerji santralleri,
 - d. Konutların ısıtılması

2.3 Hava Kirliliğine Etki Eden Faktörler

Hava kirliliğini etkileyen faktörler; meteorolojik, atmosferik, topoğrafik, kentleşme, sanayileşme ve sosyo-ekonomik yapı olarak sınıflandırılır.

2.3.1 Meteorolojik faktörler

Hava kirliliğini etkileyen meteorolojik faktörler; sıcaklık, basınç, yağış, rüzgâr ve nemdir (Kunt ve Dursun, 2018).

- **Sıcaklık**

Hava kütlesi içerisinde, ısı enerjisinin sonucu olan molekül titreşimlerinin etrafa yaptığı etkidir (Kunt ve Dursun, 2018).

Kış aylarında hava sıcaklığının düşmesi yakıt tüketimini arttırmaktadır. Bu nedenle ortaya çıkan kirleticiler hava kirliliğe yol açmaktadır.

- **Basınç**

Atmosferi oluşturan gazların ağırlıklarının atmosfer içindeki cisimlere yaptığı etkidir (Kunt ve Dursun, 2018).

Alçak basınç alanlarında alt katlardaki kirli hava yukarılara doğru çıkarak (yükseltici hava hareketleri) dağılmaktadır.

Yüksek basınç alanlarında ise sübsidans (konveksiyonel hava hareketlerinden yukarıdan aşağıya doğru olan) söz konusu olduğu için aşağıdaki kirli hava yükselememektedir.

- **Yağış**

Yağış, hava kütlelerinin soğuk hava ile karşılaşması sonucu su buharının yoğunlaşmasıyla sıvı ya da katı durumda yere düşmesi olayıdır. Yağış kirli havanın yıkanmasında etkilidir. Yağış ile kirli havadaki kirleticiler toprağa karışır. Böylece kirletici yer değiştirmiş olur.

- **Rüzgar**

Rüzgâr, dünya yüzeyine yakın, atmosfer içerisinde olan alçak basınçla yüksek basınç bölgesi arasında yer değiştiren hava akımıdır. Rüzgârlar, kirli havayı ortamdaki uzaklaştırmada ya da kirli havayı temiz ortamlara taşımakla hava kirliliğinde doğrudan etkilidir.

- **Nem**

Nem havadaki su buharı miktarıdır. Artan nem bazı kirletici konsantrasyonlarını artırırken bazı kirletici konsantrasyonlarının bir miktar azalmasında etkili olur (Kunt ve Dursun, 2018).

2.3.2 Atmosferik faktörler (inversiyon)

Atmosferin aşağı tabakalarında soğuk hava katmanının daha yukarıdaki sıcak hava katmanı tarafından tutulmasıyla oluşan sıcaklığın yükseklikle artması olayıdır. Rüzgâr olmadığı durumlarda kirleticiler dağılma olanağı bulamaz ve büyük hava kirliliği gerçekleşebilir.

2.3.3 Topoğrafik faktörler

Topoğrafik özellikler olarak dağ, ova, plato ve vadi gibi yer şekilleri ile bunların yüksek, alçak, düz ve eğimli olmaları ayrıca iklimle ilişkileri, bakı özellikleri ve su kütlelerine yakınlıkları şehirlerin hava kalitesini etkileyen faktörler arasında bulunmaktadır. Topoğrafik faktörler, yerleşim birimi üzerindeki kirli havanın kalış süresini etkilemektedir (Sağlar, 2019).

2.3.4 Kentleşme

Artan nüfus artışı ya da göçler ile kentler de artan nüfus artışına bağlı olarak çeşitli çevresel sorunlar ortaya çıkmaktadır. Kentlerdeki konut sayısı artışı, taşıt fazlalığına bağlı olarak yakıt tüketiminin artması hava kirliliğini artırmaktadır. Kış aylarında ısınmadan kaynaklanan hava kirliliğinin esas nedenleri; ısınmada kullanılan kalitesiz yakıtlar (kül, kükürt ve nem oranı fazla olup da kalorisi düşük kömürlerdir), yanlış yakma işlemleri ve kazan bakımlarının düzenli olarak yapılmamasından kaynaklanır (Kök, 2018).

2.3.5 Sanayileşme

Fabrikaların bacalarından çıkan kimyasal gazlar, tozlar ve dumanlar havayı kirletmektedir. Fabrikalarda enerji ihtiyacı için yakılan yakıtlar ve fabrikada yapılan işlemler sonucu oluşan kirleticiler baca çıkışı ile birlikte kirlilik oluşturmaktadır. Sürdürülebilirliğin sağlanması için fabrikaların mutlaka çalışması ve üretimlerini devam ettirmesi gerekir. Burada önemli olan hem kalkınmayı sürdürmek hem de çevreyi korumaktır. İşyerleri, fabrikalar çevreyi kirletmemek için alınması gereken tedbirleri almalıdır.


2.3.6 Sosyo-ekonomik yapı

Hava kirliliği ile sosyo-ekonomi arasında yakın ilişki vardır. Ekonomik gelişimin devam etmesi hava kirliliği artışına sebep olurken, hava kirliliği de ekonomik gelişme üzerinde etkili olmaktadır. Ekonomik gelişme hava kirliliğini, hava kirliliği ise ekonomik gelişmenin ekonomik ve sosyal maliyetini arttırmaktadır (Kök, 2018).

2.4 Hava Kirliliğinin Etkileri

Kirletici parametreler insan sağlığı, ekosistem, iklim değişikliği, ekonomi, kültürel miras ve yapılar üzerinde çeşitli olumsuz etkileri bulunmaktadır.

AÇA tarafından “Hepimiz için daha temiz hava” kapsamında Şekil 2.3’ de görüldüğü gibi hava kirliliğinin sebep olduğu ekonomik kayıpların önemi vurgulanmaktadır. AÇA Temiz Hava Politikası Paketi’nin uygulamaya geçmesi ile toplum üzerindeki faydasının beklenilenin 20 katından daha fazla olduğunu belirtmektedir (Tosun, 2017).



Şekil 2.3. Hava kirliliğinin oluşturduğu ekonomik maliyet

2.4.1 İnsan sağlığı üzerine etkileri

Hava kirliliği problemi birçok çevresel sorunun nedeni olarak gösterilmektedir. Hava kirliliğinin insan sağlığına olan etkilerini değerlendirmek için kirliliğin vücuda giriş şekli, vücudun kirliliğe maruz kaldığı süre, kirlilik etkeninin yoğunluğu ve kişinin genel sağlık durumunun bilinmesi gerekir. Hava kirliliği olumsuz çevresel etkileri ile birlikte doğrudan ve dolaylı olarak insan sağlığı üzerinde oldukça büyük bir sorun teşkil etmektedir. Sağlık üzerinde görülen en önemli etkisi solunum sistemi üzerinedir ve özellikle akciğer, bronşit, eklem romatizması, raşitizm ve çeşitli kalp hastalıkları, göz yanmaları, görme bulanıklığı, nefes darlığı, iştahsızlık, kan zehirlenmesi vb. gibi etkileri olmaktadır (Müezzinoğlu, 2000).

Havadaki tozların tane boyutları sağlık açısından önemli olmaktadır. Özellikle 1-5 mikron, 0,1-1 mikron ve <0,1 mikron çaplı tozların havadaki konsantrasyonlarının dağılımlarının bilinmesi önemlidir. 5 mikrondan iri taneciklerin insan vücuduna girme şansı yoktur. Ancak 1 mikrondan ince olan tanecikler gaz gibi davranarak üst ve alt solunum yollarını aşip akciğer bölmelerine girebilmektedir (Müezzinoğlu, 2000). Çizelge 2.1’de başlıca hava kirleticilerinin ana kaynağının neler olduğu ve kirleticilerin insan sağlığı üzerindeki etkileri belirtilmiştir (URL-3, 2019).

Çizelge 2.1. Hava kirletici parametrelerin ana kaynağı ve sağlık üzerine etkileri

KİRLETİCİ	ANA KAYNAĞI	SAĞLIK ETKİSİ
Kükürt dioksit	Fosil yakıt yanması	Solunum yolu hastalıkları
Azot oksitler	Taşıt emisyonları, yüksek sıcaklıkta yakma prosesleri	Göz ve solunum yolu hastalıkları, asit yağmurları
Partikül Madde	Sanayi, yakıt yanması, tarım ve ikincil kimyasal reaksiyonlar	Kanser, kalp problemleri, solunum yolu hastalıkları, bebek ölüm oranlarında artış
Karbon monoksit	Eksik yanma ürünü, taşıt emisyonları	Kandaki hemoglobin ile birleşerek oksijen taşıma kapasitesinde azalma, ölüm
Ozon	Trafikten kaynaklanan azot oksitler ve uçucu organik bileşiklerin (VOC) güneş ışığıyla değişimi	Solunum sistemi problemleri, göz ve burun iritasyon, astım, vücut direncinde azalma

Hava kirliliğinin sonuçlarından kronik solunum sistemi hastalığı olanlar, gebe ve emzikli kadınlar, çocuklar, yaşlılar ve düşük sosyo-ekonomik grupta yer alanlar daha fazla etkilenebilecektir (Tosun, 2017).

2.4.2 Ekosistem üzerine etkileri

Hava kirliliğinin ekosistem üzerine de olumsuz etkileri olabilmektedir. Hava kirliliğine neden olan kirleticiler doğrudan bitki örtüsü üzerine, dolaylı olarak ise su ve toprak üzerine etki ederek ekosistemin doğal dengesini bozmaktadır (Yücedağ ve Kaya, 2016). Bitkiler hava kirlenmesinden yaprak dokularının bozulması ile klorofil yapısının bozulmasından dolayı meydana gelen beyazlanmalar ve lekeler ile büyüme oranlarında bozulmalar meydana gelmesi ile etkilenirler.

Fosil yakıtların yanması sonucu kükürt dioksit (SO_2) gazı ve azot oksit bileşikleri doğaya salınır. Salınan bu bileşikler atmosferde oksijen, su ve diğer kimyasallar ile tepkimeye girmesi ile sülfürik asit ve nitrik asit oluşur ve yeryüzüne sis, yağmur, dolu ve kar olarak ulaşarak asit yağmurlarını oluşturur. Asit yağmurları ya doğrudan sulak alanlar ile buluşur ya da toprak tarafından emilir. Sulak alanlara yağın asit yağmurları yüzey sularının asitlik derecesinin artmasına neden olur ve bölgede ekosistem dengesinin bozulmasına yol açar.

2.4.3 İklim değışikliğı üzerine etkileri

Hava kirliliğı ve iklim değışikliğı birbiriyle bağlantılı kavramlardır. Fosil yakıt kullanımı, termik santraller, büyükbaş hayvan çiftlikleri gibi kaynaklardan havaya salınan karbondioksit hava kirliliğine ve küresel ısınmaya neden olmaktadır. Küresel ısınma olağandışı iklim olaylarına (buzulların erimesi, kuraklık, sera etkisi vb.) neden olmaktadır (Türkeş vd., 2000).

2.4.4 Kültürel miras ve yapılar üzerine etkileri

Hava kirliliğine neden olan materyaller zaman içinde yapılar üzerinde korozyon, biyodegradasyon ve topraklaşma gibi zararlar meydana getirmektedir. Mimari yapılar özellikle meydana gelen asit yağmurları ile binaların dış kısımlarının kararmasına ve aşınmasına neden olmaktadır. Bu durum da yapıların onarımı için ekonomik bir kayıp getirmektedir.

2.4.5 Ekonomik etkiler

Hava kirliliğı insan sağlığı, ekosistem, iklim değışikliğı, kültürel miras, yapılar gibi ekonomik değeri olan ya da olmayan yapılar üzerinde kayıp oluşturmaktadır. Sağlık için yapılan harcamalardaki ekstra artış, düşen mahsul verimini arttırmak için yapılan harcamalardaki artış, hava ve su kalitesindeki azalma ile ekosistemin sağlığını korumaya yönelik yapılan harcamalar, iklim değışimi kapsamındaki kayıplar ve hastalık ve ölüm artışı hava kirliliğinin oluşturduğu ekonomik kayıpları kapsamaktadır. Isınma, ulaşım ve sanayi faaliyetleri hava kirliliğinin en önemli kaynaklarıdır. Sanayi faaliyetlerinde alınacak tedbirlere çok katkı sağlanamasa da ısınma ve ulaşım faaliyetlerinde insanlar üzerlerine düşen görevleri yerine getirerek çevrenin temizliğı sağlanabilmektedir. Hava kirliliğini en aza indirmek için yapılması gerekenler:

- Yakıt tüketimi azaltılmalıdır
- Kaliteli yakıtlar kullanılmalıdır
- Temiz enerji kaynakları kullanılmalıdır
- Isı yalıtımı yapılmalıdır


- Bacalar düzenli olarak temizlenmelidir
- Genel çevre koruma ve tasarruf tedbirleri uygulanmalıdır
- Sanayi bölgelerinde bacalara filtreler takılmalı ve düzenli olarak filtreler kontrol edilerek temizlenmelidir
- Hava sirkülasyonunu bozacak inşaatlar yapılmamalıdır
- Yeşil alanlar çoğaltılmalı ve bu alanların korunması sağlanmalıdır
- Ulaşımında özel araç kullanımı yerine toplu taşıma araçları tercih edilmelidir
- Araç egzozlarına filtre takılmalı düzenli olarak muayenesi yapılmalıdır
- Hava kirliliği hakkında bilinçlendirme çalışmaları yapılmalıdır
- Ozon tabakasına zarar veren kimyasallar fabrikalar tarafından kullanılmamalıdır
- Orman alanlarında yakıcı maddeler kullanılmamalıdır.

2.5 Dünyada ve Türkiye’de Hava Kirliliği

Hava kirliliği, insan sağlığı ve çevre üzerinde olumsuz etki bırakmaktadır. Hava kirliliği düzeyleri düzenli olarak takip edilmesine rağmen bütün dünyada kabul edilen sınırların üzerinde seyretmektedir. Hava kirliliği özellikle endüstriyel tesislerden, yakıt kullanımından ve motorlu taşıt egzozundan kaynaklanmaktadır.

Hava kirliliği, 1934’te Belçika’da Meuse Vadisinde, 1947’de ABD’de Donora’da ve 1952’de Londra’da yaklaşık 1 ay boyunca hava kirliliği (çok yüksek PM emisyonu) maruziyeti dolayısıyla binlerce insanın yaşamını yitirmesi ile ortaya çıkmıştır. Bu felaket sonucu önlem amaçlı emisyon kontrolünün ve kömür kullanımı gibi kısıtlamaların yapıldığı kaydedilmiştir. Hava kirliliği kontrolünde yasal sürecin ortaya çıkması ile birçok ülkede yerel ve Dünya Sağlık Örgütü (DSÖ) tarafından belirlenen kirletici sınır değerleri ve emisyon kriterleri kullanılmaktadır (Bayram vd., 2006).

DSÖ’nün küresel verilerden derlediği 2018 raporunda; zengin ve fakir ülkeler arasındaki hava kirliliği oranlarında eşitsizlik olduğu belirtilmektedir. Raporda her 10 kişiden dokuzunun kötü hava soluduğu belirtilmektedir. Raporda Amerika kıtasındaki şehirlerin %57’sinde, Avrupa kıtasındaki şehirlerin %61’inde 2010’dan 2016 yılına kadar PM₁₀ ve PM_{2,5} oranlarında bir düşüş görülmektedir (URL-4, 2019).



Şekil 2.4. Dünya’da 2010’dan 2016 yılına doğru hava kirlilik değişimi

Şekil 2.4’te görüldüğü gibi hava kirliliğinin en kötü etkilendiği ülkeler güney ve güneydoğu Asya ülkeleridir. DSÖ’nün belirlediği PM seviyesinin en yüksek olduğu en kirli mega şehirler Hindistan’ın Delhi ve Mısır’ın Kahire şehirleridir (URL-5, 2019).

Dicle Tıp Dergisi’nin 2006 yılında yayınladığı çalışmaya göre dünyada hava kirlleticilerinde 2030 yılına kadar beş kat oranında artış beklenmektedir (Bayram, 2006). Özellikle gelişmekte olan ülkelerde hızlı kentleşme ve enerji tüketimi ile kirlilik artmaktadır.

İki farklı araştırma gösteriyor ki gelişmekte olan ülkelerde hızlı kentleşme ve enerji tüketiminin artışına bağlı olarak alınan önlemlerin yeterli olmaması, gelişmeyen ülkelerde de kirliliğin azaltılmasını sağlamak adına yeterli önlemler alınamaması hava kirliliğinin artışına neden olmaktadır.

2020’de yapılan araştırma sonucunda dünyada hava kirliliğinin en fazla olduğu 15 ülke;

Bangladeř, Pakistan, Hindistan, Afganistan, Bahreyn, Moęolistan, Kuveyt, Nepal, Birleşik Arap Emirlikleri, Nijerya, Endonezya, Çin, Uganda, Bosna-Hersek ve Kuzey Makedonya'dır.

Türkiye'de de durumun çok farklı olmadığı Şekil 2.5'te görölmektedir. DSÖ'nün verilerine göre yüksek oranda partikül madde kirliliğine maruz kalındığı görölmektedir (URL-5, 2019).



Şekil 2.5. Dünya Sağlık Örgütü'nün sınır deęerlerine göre Türkiye'nin PM kirlilięi

Türkiye'de özellikle 1950 yılından sonra nüfusun hızlı artışı buna baęlı olarak hızlı kentleşme ve endüstrileşme ile enerji kullanımının artması hava kirliliğini artırmaktadır. Bu artış halk saęlığı problemlerini de arttırmıştır. Türkiye'de şehirlerde hava kalitesi deęerlerini belirten istatistikler, SO₂ ve PM gibi kirlетici konsantrasyonlarının Çizelge 2.2'de belirtildięi gibi özellikle kış aylarında Türkiye Hava Kalitesini Koruma Yönetmelięi'nin belirledięi sınırların üzerine çıktığını göstermektedir. Ayrıca bu verilerin belirlenen hedef sınır deęerlerinin ve DSÖ'nün ve AB'nin belirledięi standartların da üzerinde olduęu belirtilmektedir (Bayram, 2005).

Çizelge 2.2. Türkiye Hava Kalitesini Kontrol Yönetmeliği'ne (THKKY) göre belirlenen kısa ve uzun dönem sınır değerler ile DSÖ ve AB hava kalite değerleri (Elbir vd., 2000).


	SO ₂ (µg/m ³)	PM (µg/m ³)
THKKY		
Kısa dönem sınır değerler	400	400
Uzun dönem sınır değerler	150	150
Kış dönemi (ekim-mart) sınır değerleri	250	200
DSÖ		
Günlük maksimum değer	125	-
Yıllık ortalama	50	-
AB		
Günlük maksimum değer	125	-
Uzun dönemli değer	50	-
Yıllık ortalama	-	80
SO ₂ : kükürt dioksit, PM: partikül madde		

Çevre sağlığı ile ilgili ilk yönetmelik 1930'da hazırlanmıştır. Sonraki yıllarda Ankara'daki hava kirliliği sorunu hükümet programlarında yer almaya başlamıştır. 1961 yılında ilk kez Sağlık Bakanlığı Ankara'da iki farklı noktada SO₂ ve duman ölçümlerine başlamıştır. 1983 yılında TBMM tarafından Çevre Yasası hazırlanmış ve kabul edilmiştir. Bu yasa ile kirlетici kaynak belirlenip kontrol altına alınarak çevre ve doğal kaynakların korunması amaçlanmıştır. Bu yönetmelik ile hava kalitesi ölçütleri, belirlenen hava kalite değerleri ve endüstriyel kuruluşlar için emisyon düzeyleri belirlenmiştir (Bayram, 2005).

Türkiye'de 2019 yılında hazırlanan hava kirliliği raporuna göre 75 milyon kişi kirli hava solumaktadır. Raporda Türkiye'de hava kirliliğini belirlemek için solunum yolu enfeksiyonları, akciğer hastalıkları, astım gibi sağlık sorununa neden olan PM_{2,5}, PM₁₀, SO₂(kükürt dioksit), NO₂(azot dioksit), CO (karbon monoksit) ve O₃(ozon) gibi parametrelerin sınırlarının aşıldığı gün sayıları ve yıllık ortalama değerleri incelenmiştir. Raporda en yoğun hava kirliliğinin olduğu kentler; Bursa, Adana, Ankara, İstanbul, Iğdır, Şırnak, Muş, Manisa, Kahramanmaraş, Karabük, Çanakkale, Denizli, Zonguldak, Edirne-Keşan, Şanlıurfa olarak belirtilmektedir (URL-6, 2020).


2020 yılında tüm dünyayı etkisi altına alan milyonlarca insanın ölümüne neden olan COVID19 salgını bir kez daha halk sağlığının önemini vurgulamıştır. Salgın nedeniyle karantina uygulamaları, sokağa çıkma yasakları, uçuşların durdurulması sürecinin başlaması ile hava kirliliği tekrar gündeme gelmiştir. Bu süreç içerisinde havanın %60'lara varan oranda temizlendiği tespit edilmiştir. Kirli havanın solunum sisteminin savunma mekanizmalarını bozarak bireylerin, koronavirüs gibi zararlı mikroorganizmalardan daha fazla etkilenmesine sebep olduğu yapılan araştırmalarda belirtilmiştir (URL-7, 2020)

Hava kirliliği üzerine bilgilendirme çalışmaları yapan IQAir şirketi bünyesinde yapılan araştırmada dünya genelinde koronavirüs vakalarının fazla olduğu ve karantina uygulaması yapan Wuhan, Yeni Delhi ve Mumbai'yi de içeren 10 kent incelemeye alınmıştır. Araştırmada akciğere yerleşebilen ve kana karışarak ciddi sağlık sorunlarına neden olan PM_{2,5} değerlerine bakılmış ve yüksek seyreden PM_{2,5} değerinde Şekil 2.6'da görüldüğü gibi karantina sürecinde kayda değer düşüşler saptanmıştır (URL-8, 2020).



Şekil 2.6. Karantina sonucu hava kirliliği oranındaki azalma yüzdesi

Koronavirüs ile mücadelenin ağır seyrettiği İtalya'da da karantina uygulamalarının başlamasıyla şubat ve mart ayında uydudan sağlanan görüntüler hava kirliliğinin gözle görülür oranda azaldığını göstermektedir (URL-8, 2020). Şekil 2.7'de İtalya'nın Şubat ve Mart ayı hava kirliliği uydu görüntüsü mevcuttur.



Şekil 2.7. İtalya’nın Şubat ve Mart ayı hava kirliliği uydu görüntüsü (URL-9, 2020)

İstanbul Büyükşehir Belediyesi İstatistik Ofisi’nin yayınladığı verilerde, 1-12 Nisan 2020 tarihleri arasında İstanbul’da hava kalitesinin %28,6 oranında iyileştiği görülmektedir. Bugünlerde 39 olarak belirlenen Hava Kalite İndeksinin (HKİ), Mart ayında 55 olarak ölçüldüğü belirtilmektedir (URL-9, 2020).

2.6 Hava Kalitesi Kavramı ve Modellemesi

“Hava kalitesi” terimi, çevremizdeki hava durumu anlamına gelir. Yaşam kalitemizin yüksek olması yaşadığımız ortamdaki hava kalitesinin yüksekliğine bağlılık göstermektedir. Bir bölgede oluşan hava kirliliği sadece o bölge için tehlike arz etmeyip hava olayları neticesinde yayılım göstermektedir. Bu nedenle hava kalitesi ölçümleri oldukça önemlidir.

Hava kalite standartlarının amacı, atmosfere yayılan hava kirleticileri kontrol altına almak, kirleticilerin canlı yaşamına ve çevreye zarar verecek seviyeye ulaşan konsantrasyonlarından korumaktır. Türkiye’de, 9/8/1983 tarihli ve 2872 sayılı Çevre Kanununun Ek 6 ncı maddesi ile 1/5/2003 tarihli ve 4856 sayılı Çevre ve Orman Bakanlığının Teşkilat ve Görevleri Hakkında Kanunun 1 inci, 2 nci ve 9 uncu maddelerine dayanılarak ve Avrupa Birliğinin 96/62/EC, 99/30/EC, 2000/69/EC,

2002/3/EC ve 2004/107/EC sayılı direktiflerine paralel olarak Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği hazırlanmış ve 6 Haziran 2008 tarihinde yürürlüğe girmiştir (Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği, 2008). Çizelge 2.3’ te Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliğinde belirlenen SO₂, NO_x ve PM₁₀ için sınır değerler belirtilmiştir.

Çizelge 2.3. SO₂,NO₂, NO_x ve PM10 için sınır değerler (Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği, 2008)

Kirletici	Ortalama süre	Limit değeri	Tolerans payı	Üst değerlendirme eşiği	Alt değerlendirme eşiği	Limit değere ulaşılacak tarih	Uyarı eşiği
SO ₂	saatlik -insan sağlığının korunması için-	350 µg/m ³ (bir yılda 24 defadan fazla aşılmaz)	1.1.2014 tarihinde 150 µg/m ³ (limit değerin %43’ü) ve 1.1.2019 tarihine kadar tolerans payı sıfırlanacak şekilde her 12 ayda bir eşit miktarda yıllık olarak azaltılır			1.Ocak 2019	500 µg/m ³ (hava kalitesinin temsili bölgelerinde bütün bir "bolge" veya "alt bolgede" veya en azından 100 km ² -de hangisi küçük ise- üç ardışık saatte ölçülür)
	24 saatlik -insan sağlığının korunması için-	125 µg/m ³ (bir yılda 3 defadan fazla aşılmaz)	1.1.2014 tarihinde 125 µg/m ³ (%100) ve 1.1.2019 tarihine kadar tolerans payı sıfırlanacak şekilde her 12 ayda bir eşit miktarda yıllık olarak azaltılır	24-saatlik limit değerin %60’ı (75 µg/m ³ bir yılda 3 defadan fazla aşılmaz)	24-saatlik limit değerin %40’ı (50 µg/m ³ bir yılda 3 defadan fazla aşılmaz)	1.Ocak 2019	
	yıllık ve kış dönemi (1 Ekim den 31 Mart’a kadar) - ekosistemin korunması-	20 µg/m ³		Kış dönemi limit değerin %60’ı (12 µg/m ³)	Kış dönemi limit değerin %40’ı (8 µg/m ³)	1.Ocak 2014	
Kirletici	Ortalama süre	Limit değeri	Tolerans payı	Üst değerlendirme eşiği	Alt değerlendirme eşiği	Limit değere ulaşılacak tarih	Uyarı eşiği
NO ₂	saatlik -insan sağlığının korunması için-	200 µg/m ³ (bir yılda 18 defadan fazla aşılmaz)	1.1.2014 tarihinde 100 µg/m ³ (%50) ve 1.1.2024 tarihine kadar tolerans payı sıfırlanacak şekilde her 12 ayda bir eşit miktarda yıllık olarak azaltılır	limit değerin %70’i (140 µg/m ³ bir yılda 18 defadan fazla aşılmaz)	limit değerin %50’si (100 µg/m ³ bir yılda 18 defadan fazla aşılmaz)	1.Ocak 2024	400 µg/m ³ (hava kalitesinin temsili bölgelerinde bütün bir "bolge" veya "alt bolge" de veya en azından 100 km ² -de hangisi küçük ise- üç ardışık saatte ölçülür)
	yıllık -insan sağlığının korunması için-	40 µg/m ³	1.1.2014 tarihinde 20 µg/m ³ (%50) ve 1.1.2024 tarihine kadar tolerans payı sıfırlanacak şekilde her 12 ayda bir eşit miktarda yıllık olarak azaltılır	limit değerin %80’i (32 µg/m ³)	limit değerin %65’i (26 µg/m ³)	1.Ocak 2024	
NO _x	yıllık - vejetasyonun korunması için-	30 µg/m ³	-	limit değerin %80’i (24 µg/m ³)	limit değerin %65’i (19,5 µg/m ³)	1.Ocak 2014	

Çizelge 2.3. (Devamı) SO₂,NO₂, NO_x ve PM₁₀ için sınır değerler (Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği, 2008)

Kirletici	Ortalama süre	Limit değeri	Tolerans payı	Üst değerlendirme eşiği	Alt değerlendirme eşiği	Limit değere ulaşılacak tarih
PM ₁₀	24 saatlik -insan sağlığının korunması için-	50 µg/m ³ (bir yılda 35 defadan fazla aşılmaz)	1.1.2014 tarihinde 50 µg/m ³ (% 100) ve 1.1.2019—tarihine kadar tolerans payı sıfırlanacak şekilde her 12 ayda bir eşit miktarda yıllık olarak azaltılır	30 µg/m ³ (bir yılda 7 defadan fazla aşılmaz)	20 µg/m ³ (bir yılda 7 defadan fazla aşılmaz)	1 Ocak 2019
	Yıllık -insan sağlığının korunması için-	40 µg/m ³	1.1.2014 tarihinde 20 µg/m ³ (% 50) ve 1.1.2019 tarihine kadar tolerans payı sıfırlanacak şekilde her 12 ayda bir eşit miktarda yıllık olarak azaltılır	14 µg/m ³	10 µg/m ³	1 Ocak 2019

Hava kalitesi ölçümleri yapılırken; bölgedeki kirlenmenin yanında bölge dışından taşınan kirletici konsantrasyonları belirlenmeli, hava kalitesi tespiti için uygun yer ve yeterli sayıda istasyon kurulmalı, meteorolojik ve topoğrafik faktörler de dikkate alınmalı ve kirletici seviyesi belirlenen sınır değerlerin üzerine çıktığı durumlarda gerekli önlemlerin alınması gerekmektedir.

Hava kalitesi hakkında bireylerin kolay ve anlaşılır şekilde bilgilendirilmesi için hesaplanan değerler uygun ve doğru şekilde paylaşılmalıdır. Bu paylaşımında hava kalite indeksi ile günlük hava kalitesinin iyi, orta, sağlıklı, kötü veya zararlı olduğu hakkında bilgi verilmektedir. Hava kalitesi izleme teknikleri avantaj ve dezavantajlarıyla Çizelge 2.4’te mevcuttur.

Hava kalitesi izleme metotları;

- Pasif örnekleyiciler
- Aktif örnekleyiciler
- Otomatik analizörler
- Uzaktan algılayıcılardır.

Pasif örnekleyiciler: Bu örnekleyiciler genellikle silindirik ve tüp şeklinde olup gaz ve buhar yapıdaki kirleticileri, atmosferdeki statik tabakada veya bir membran içerisinde geçişme ve yayılma gibi fiziksel işlemler ile alabilen cihaz olarak tanımlanır. Bu örnekleyicinin avantajı kolaylığı ve başlangıç maliyetinin düşük olmasıdır (Akcan ve Yeşilyurt, 2001).

Aktif örnekleyiciler: Bu örnekleyiciler, pasif örnekleyicinin aksine kirletici numunesinin kimyasal veya fiziksel bir ortamdan geçirilebilmesi için elektrik enerjisine ihtiyaç duyarlar. Bu örnekleyiciler ile günlük ortalama ölçümler elde edilebilir. Pasif örnekleyiciye göre daha karmaşık yapılı ve pahalıdır. Buna rağmen işletilmesi bir o kadar kolay olduğundan sonuçlar daha güvenilir olmaktadır.

Otomatik analizörler: Otomatik analizörler, kirletici numunesinin fiziksel ve kimyasal özelliklerinden faydalanarak ya doğrudan ya da kimyasal ısıma yoluyla sürekli tayinlerine olanak sağlarlar. Bu cihazların ilk yatırım maliyetleri ve işletme masrafları yüksektir. Ayrıca işletilmesi için deneyimli insanlara ihtiyaç vardır. Verilerin işletilmesi ve analizinin yapılması için bilgisayar destekli sistemlere ihtiyaç duyar (Akcan ve Yeşilyurt, 2001).

Uzaktan algılayıcılar: Uzaktan algılayıcılar otomatik analizörlere kıyasla çok bileşenli ölçümlerin yapılmasına olanak sağlar. Kaynak yakınındaki araştırmalarda ve atmosferdeki dikey ölçümlerde fayda sağlamasına rağmen çok karmaşık ve pahalı cihazlar olduğundan kalite güvenilirliği açısından zorluklar yaşanabilir (Aydınlar vd., 2009). Ayrıca başarılı bir şekilde işletilmesi için deneyimli insan gücü ve iyi bir kalite kontrol programına ihtiyaç vardır.

Çizelge 2.4. Hava kirliliği izleme teknikleri

YÖNTEM	AVANTAJLAR	DEZAVANTAJLAR	MALİYET
Pasif Örnekleyiciler	• Maliyeti düşük • Basit • Tarama ve ilk başlangıç çalışmaları için kullanışlı	• Bazı kirleticiler için ispatlanmamıştır • Genellikle sadece haftalık ve aylık ortalama sağlar	2-4 \$/ numune
Aktif Örnekleyiciler	• Maliyeti düşük • Kolay işletilebilir • Güvenilir	• Günlük ortalamaları sağlar • Laboratuvar analizi gerektirir	2-4 bin \$/ birim
Otomatik Analizörler	• İspatlanmış • Yüksek performanslı, saatlik veri alınması • On-line bilgi temini	• Karmaşık • Tecrübe gerektirir • Kurulum ve İşletme maliyeti yüksek	10-20 bin \$/ analizör
Uzaktan Algılama Cihazları	• Bir hat boyunca veri temini • Kaynakların yakın çevresi ve atmosferde dikey ölçümler için kullanışlı olması • Çok bileşenli ölçümlerin yapılmasına olanak tanınması	• Karmaşık yapılı • Maliyeti yüksek • Desteklemek, işletmek, kalibre etmek ve geçerliliğini onaylamak zordur • Geleneksel analizörler ile her zaman karşılaştırılabilir sonuçları vermez	>200 bin\$/ algılayıcı

Hava kalitesi modellemesi, emisyonlar, meteoroloji, atmosferik konsantrasyonlar, birikim ve diğer faktörler arasındaki nedensel ilişkiyi tanımlamak için kullanılan sayısal bir araçtır. Bu modeller, meteorolojik veri girdileri, emisyon oranları ve baca yüksekliği gibi kaynak bilgilerine dayanarak, doğrudan atmosfere yayılan birincil kirleticileri ve bazı durumlarda atmosfer içindeki karmaşık kimyasal reaksiyonların bir sonucu olarak oluşan ikincil kirleticileri karakterize etmek için tasarlanmıştır. Hava kalitesi ölçümlerinin yapılamadığı yerlerde modelleme çalışmaları, o bölgelerdeki kirlilik

kaynakları ile çevre hava kalitesi üzerindeki etkileri arasındaki ilişkiyi tahmin etmek, hava kalitesi sorunlarına kaynak katkılarını belirlemek, zararlı hava kirleticilerini azaltmak, etkili stratejilerin tasarımına yardımcı olmak, izin verme sürecinde yeni bir kaynağın ortam hava kalitesi standartlarını aşmayacağını doğrulamak veya gerektiğinde uygun ek kontrol gereksinimlerini belirlemek için hava kirliliğini kontrol etmekle görevli kurumlar tarafından yaygın olarak kullanılmaktadır.

Genellikle tercih edilen hava kalitesi modelleri; dispersiyon, fotokimyasal ve reseptör modellemelerdir. Dispersiyon modellemesi, kirleticilerin yer seviyesi reseptörlerindeki konsantrasyonunu tahmin etmede; fotokimyasal modelleme, kirleticilerin atmosferdeki fiziksel ve kimyasal değişimlerini ele alarak bölgesel kalite ölçümüne gerek kalmadan kirletici konsantrasyon tahmininde, reseptör modelleme ise kirletici kaynaktan ölçülen partiküllerin kimyasal ve fiziksel özelliklerinin belirlenmesinde reseptör varlığını tanımlamak ve reseptöre kaynak katkıları ölçmek için kullanılmaktadır (Aydınlar vd., 2009).

Modelleme çalışmalarında sıklıkla tercih edilen programlar aşağıda verilmiştir;

ADAM (Air Force Dispersion Assessment Model – Hava Kuvvetleri Dağılım Değerlendirme Modeli): Noktasal, alansal, basınçlı, basınçsız, sıvı, buhar ve iki fazlı kirleticileri modelleyebilmektedir.

AERMOD: Hava kirletici emisyonlarının kısa menzilli dağılımı için tasarlanmış kararlı durum dağılım modelidir (Orloff vd., 2011).

ASPEN (The Assessment System for Population Exposure Nationwide – Ülke Çapında Nüfus Maruziyeti için Değerlendirme Sistemi): ASPEN dağılım ve harita modüllerinden oluşmaktadır. Kaynak yakınlarına yerleştirilen alıcı noktalarındaki yıllık ortalama konsantrasyonlarının tahmininde kullanılmaktadır.

BLP (Buoyant Line and Point Source – Yüzen Çizgi ve Noktasal Kaynak): Alüminyum indirgeme tesisi ve diğer endüstriyel kaynaklardan meydana gelen kirleticilerin dağılımını hesaplayabilmektedir.

CALINE 3 ve CALINE 4: Kararlı hal dağılım modelidir. Karmaşık olmayan arazilerde çizgisel kaynak yakınlarındaki alıcı noktalarındaki kirletici konsantrasyonlarını hesaplayabilmektedir.

CTDMPLUS (Complex Terrain Dispersion Model Plus Algorithms for Unstable Situations – Kararsız Durumlar için Algoritmali Karmaşık Arazi Dağılım Modeli): Karmaşık arazi yapısı için kararlı koşullarda hesaplama yapabilmektedir.

CTSCREEN: Karmaşık arazi yapılarında düzenleyici uygulamalar için dağılım tahminleri yapabilmektedir.

ISCST-3 (Industrial Source Complex Short Term Version 3 – Endüstriyel Kaynak Karmaşık Kısa Dönemli 3): Kirlilik kaynaklarının çeşitli olduğu yerlerde, emisyonların dağılımlarının modellenmesi yönünde farklı seçenekler sunabilen bir modelleme yaklaşımıdır. Hava kalitesi tahminleri için uygun bir model olarak görülmektedir.

OCD (Offshore and Coastal Dispersion – Açık Deniz ve Kıyısız Dağılım): Noktasal, alansal ve çizgisel kaynaklardan meydana gelen emisyonları kıyı boyunca veya açık denizdeki dağılımını hesaplamaktadır.

RTDM 3.2 (Rough Terrain Diffusion Model – Engebeli Arazi Dağılım Modeli): Doğrusal, kararlı hal modelidir. Yer seviyesindeki konsantrasyonların tahmini için kullanılmaktadır.

SCREEN 3: Noktasal, alansal ve hacimsel kaynaktan gelen kirleticilerin tahmininde ve yer seviyesindeki konsantrasyon ve gideceği maksimum mesafelerin tahmininde kullanılmaktadır.

SDM (Shoreline Dispersion Model – Sahil Dağılım Modeli): Kıyı şeridi yakınlarındaki noktasal kaynaklardan meydana gelen konsantrasyonları tanımlamaktadır.

TSCREEN (Toxics Screening Model – Sahil Dağılım Modeli): Farklı kaynaklardan yayılabilen toksik gazların düzgün analizini yapabilen modeldir.

VALLEY: Kararlı hal ve karmaşık arazi yapılı, tek değişkenli modeldir.

Hava kalitesi değerlendirmesinde modelleme programlarının kullanımı kullanılan bilgisayar teknolojilerinin gelişmesi sayesinde günümüzde oldukça yaygınlaşmıştır. Hava kalitesinin birebir ölçülmesinin zorlukları arasında; ölçüm cihazlarının maliyeti, kullanım zorlukları ve uygun ölçüm noktalarının belirlenmesi gelir. Kullanılan tüm modelleme sistemleri kesin ve doğru sonuçlar vermemektedir. Günümüzde trend olan bir diğer model programı makine öğrenmesidir. Açık bir şekilde programlama yapmadan yüksek performans elde ederek sonuçları doğru tahmin etmeyi sağlayan bir algoritma kategorisidir (Demirarslan, 2015).

BÖLÜM III

MAKİNE ÖĞRENMESİ

3.1 Makine Öğrenmesi Kavramı ve Adımları


Makine öğrenmesi, ele alınan problemin çözümünü kendi kendine öğrenebilen, karmaşık algılama ve veriye dayalı karar verebilme özelliği olan bilgisayar algoritmalarının adıdır. Mevcut olan veriler ve makine öğrenmesi yöntemleri kullanılarak elde edilen model ile en yüksek performansta sonuçlara ulaşmak amaçlanmaktadır (Şahin, 2018).

Makine öğrenimi, bilgisayarların algılayıcı verisine dayalı öğrenimini olanaklı kılan veriler üzerinde tahmin yapabilen algoritmaların inşasını ve geliştirme süreçlerini konu edinen bir bilim dalıdır. Bu algoritmalar örnek veri ile beslenir ve bu veriye dayanarak bir model geliştirir. Makine öğrenmesi algoritmaları eldeki ham veriyi kullanmadan önce bu verileri temsil eden daha anlamlı veriler çıkartırlar (Şahin, 2018). Makine öğrenmesine ait yöntemler Şekil 3.1’de mevcuttur. Bu başlıca kavramlar:

- **Denetimli Öğrenme:** Belirsizlik durumunda kanıtlanabilir tahminler veren model oluştururlar. Denetimli öğrenme algoritması ile bilinen bir girdi verisine bilinen yanıtlar alınır ve yeni veri yanıtına karşılık doğru tahmin oluşturmak üzere modeli eğitir.
- **Denetimsiz Öğrenme:** Modelin denetlenmesine gerek kalmadan, bilgileri keşfetmek için kendi başına çalışan öğrenme tekniğidir. Denetimsiz öğrenmede sistem öğretilmiyor verilerden öğreniyor.
- **Yarı Denetimli Öğrenme:** Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenmenin arasında yer alır. Yarı denetimli öğrenme; denetimli öğrenmedeki etiketlenmiş veriler ile denetimsiz öğrenmedeki etiketsiz verileri içerisinde bulundurulur.
- **Takviyeli Öğrenme:** Bulunduğu ortamı algılayan ve tek başına karar alabilen sistemin nasıl doğru sonuç elde edeceğini öğretir.

- **Pekiştirmeli Öğrenme:** Amaca yönelik ne yapılması gerektiğini öğrenen, karşılaştığı durumlarda sayısal bir ödül sinyali alan ve bu ödülü maksimuma çıkarmak için deneme yanılma yöntemi ile çalışan makine öğrenmesi yaklaşımıdır (Rende vd., 2017).

Bir makine öğrenmesi modelinin uygulanması belirli aşamalar ile gerçekleştirilmektedir. Uygulamanın yapılabilmesi için öncelikle veriler toplanmakta ve ön işleme alınmaktadır. Daha sonra veri temizleme ve dönüştürme işlemi gerçekleştirilmektedir. Ardından veri eğitimi ve test setlerine ayrılır. Daha sonra eğitim verileriyle algoritmanın model geliştirmesi sağlanır. Son olarak test verileriyle algoritmanın başarısı ölçülür.



Şekil 3.1. Makine öğrenmesi yöntemleri (Şahin, 2018)

3.2 Makine Öğrenmesi Algoritmaları

3.2.1 Karar ağaçları (decision trees)

Karar ağaçlarının amacı veri setinde değişkenleri kullanarak hedeflenen değeri tahmin edebilecek bir ağaç modeli oluşturmaktır. Karar ağaçları kök ile başlar. Bütün veriler düğüm adı verilen karar verme noktalarından geçerek dallara ayrılır ve yapraklara

ulařır. Dügüm sonucunda verilen karar çeřitililięine göre dallar oluřturulur. Son olarak dallar yapraklara yani sınıflandırılan ya da sayısal deęer atanan bir çıktı deęerlerine ulařır. Dallar birbirine karıřmazlar, düęüm ařamalarından geęerek yukarıdan ařaęıya doęru aęaę bięimine benzer bir yapı oluřtururlar. Karar aęacı regresyon yönteminin; sonuçların rahat yorumlanabilmesi, eęitim ve uygulama sürecinin hızlı olması ve anlaşılır görseller sunabilmesi gibi avantajları vardır (James vd., 2013; Swetapadma ve Yadav, 2017). Karar aęacı yöntemindeki en önemli nokta kök düęümlerden itibaren bütün düęümlerin hangi kritere göre ve nasıl dallanacaęına karar vermektir.

3.2.2 Torbalama (bagging - bootstrap aggregation)

Torbalama yöntemi ile veri setinde modelin eęitilmesi için kullanılacak olan eęitim seti daha küçük parçalara bölünür. Ardından bu farklı eęitim setleri tek bir algoritmanın eęitilmesi için kullanılarak farklı modeller oluřturulur. Modellerin tahmin ettięi sonuçlar oylama (voting) ile elenerek ya da ortalama alınarak sonuca ulařılır. Buradaki ana düşünce birbirinden farklı eęitim seti ile eęitilen modelin tek bir eęitim seti ile eęitilen modele göre daha iyi sonuç çıkaracaęı varsayımıdır (Breiman, 1996; James vd., 2013). Torbalama yöntemi rastgele orman yöntemine benzerlik gösterir. Aralarındaki en büyük fark, rastgele orman yönteminde aęacın her bir düęümü için deęiřkenler arasından rastgele bir alt küme seęilir. Bu seęim orman içindeki aęaęların birbirine benzeme ihtimalini düşürür.

3.2.3 Rastgele orman (random forest)

Rastgele orman yönteminde birden fazla karar aęacı oluřturularak bir orman meydana getirilir. Her bir aęacın verdięi sonuçlar oylama (voting) ile elenerek ya da ortalama alınarak problemin çözümüne ulařılır. Rastgele orman yöntemi, torbalama (bagging) ve Random Subspace yöntemlerinin harmanlanmasından ortaya çıkmıřtır. Torbalama yönteminde olduęu gibi veri seti alt kümelere ayrılır. Random Space yönteminde uygulandıęı üzere aęaę üzerindeki düęümlerden en iyi dallara ayrılan deęiřken, tüm deęiřkenler arasından rastgele seęilerek oluřturulan alt küme ięerisinden seęilir (Karakoyun ve Hacıbeyoęlu, 2014).

3.2.4 Artırma (boosting)

Karar ağaçlarından elde edilen sonuçları iyileştirmenin diğer bir yolu da Artırma (Boosting) yöntemidir. Torbalama yöntemine çok benzemekle beraber ağaçların dallanması açısından farklılık gösterir. Torbalama yönteminde veri seti kopyalanarak her bir kopya için farklı karar ağaçları oluşturulur. Daha sonra bu ağaçlar birleştirildiğinde bir tahmin modeli ortaya çıkar. Bu ağaçlar oluşum sırasında birbirlerinden etkilenmezler. Ancak, Artırma (boosting) yönteminde ağaçlar daha önce büyüyen ağaçlardan elde ettikleri bilgileri kullanarak birbirleriyle etkileşim (sequential) halinde büyürler (Şahinarslan, 2019).

3.2.5 Gradyan artırma (gradient boosting)

Gradyan artırma modeli karar ağaçlarının tahminini iyileştirmek için geliştirilmiş bir modeldir. Rastgele Orman ağaçları modelinden daha önce geliştirilmiştir (Friedman, 2001). Gradyan Artırma Regresyon modeli için uygulama adımları aşağıda sıralanmıştır;

- Regresyon ağacı oluşturulur.
- Her bir ağacın yaprağı için hata oranı hesaplanır.
- 2. adımda hesaplanan hata oranları yeni gözlem verileri olarak kullanılır.
- İkinci ağaç 2. adımdaki hata oranlarını en aza indirmeyi hedefler
- 2. ve 4. adımlar tekrar edilir.

3.2.6 Ekstrem gradyan artırma (extreme gradient boost, XGBoost)

Ekstrem Gradyan Artırma (XGBoost) algoritması sonuçların performansı ve çalışma hızı açısından gradyan artırma algoritmasının geliştirilmiş halidir. Makine öğrenmesi problemlerini çözmek için kullanılan bir algoritma paketidir. Milyonlarca örnekleme az miktarda kaynak kullanarak çözebilen verimli bir algoritmadır.

XGBoost algoritması milyonlarca veri setini kısa zamanda ve diğer algoritmalara göre daha az işlemci gücü ve geçici belleğe (ram) ihtiyaç duyarak analiz edebildiği için

birçok makine öğrenmesi ve veri analizi problemlerinin çözümünde kullanılmıştır (Şahinarslan, 2019).

3.2.7 Light gradyan artırma (light gradient boosting, LightGBM)

Light Gradyan Artırma (LightGBM) algoritması karar ağaçlarını kullanan farklı bir gradyan artırma modelidir. Diğer karar ağaçları analiz sürecinde dikey bir şekilde dallanma yaparken, LightGBM yapraklar üzerinden yatay dallanma yoluna gider. En büyük delta değerine sahip yaprak üzerinden karar ağacı dallanmaya devam eder. LightGBM diğer gradyan artırma modelleri ile karşılaştırıldığında hızlı işlem yapması, daha büyük verileri işleyebilmesi, daha az bilgisayar hafızasına (ram) ihtiyaç duyarak analizleri gerçekleştirebilmesi gibi avantajları vardır. LightGBM, veri seti üzerinde diğer modellere nispetle daha kolay aşırı uyum (overfitting) sağladığından büyük veri setlerinde daha iyi sonuçlar vermektedir. Farklı veri setleri üzerinde yapılan çalışmalarda LightGBM modelinin veriyi öğrenme sürecinin diğer modellere göre daha hızlı olduğu sonucuna varılmıştır (Ke vd., 2017).

3.2.8 Ekstra rastgele orman (extra tree regressor)

Rastgele Orman metodunun farklı bir versiyonudur. Rastgele orman metodunda olduğu gibi veri setinin kopyaları kullanılarak model eğitilir, ancak düğümlerin dallara ayrılma aşamasında karar kriteri kullanarak optimum ayrılmayı yapmak yerine rastgele dallanma yoluna gider. Bu fikir, bazı veri analizi problemlerinin çözümünde karmaşıklığı ve işlem yükünü azaltmasına rağmen yüksek gürültü barındıran büyük veri setlerinin analizinde performansı düşüktür. İstatistiksel açıdan değerlendirildiğinde bu metod genellikle bias artışına sebep olurken varyansı düşürür (Geurts vd., 2006).

3.2.9 Adaboost

Topluluk (ensemble) algoritmalarından biri olan bu yöntemde ise torbalama yönteminde olduğu gibi veri seti rastgele parçalara bölünür. Her bir parça farklı bir algoritma ile öğrenilir ve test edilir. Test sonucunda yanlış tahmin edilen veri parçaları farklı bir algoritma ile tekrar öğrenilerek tekrar test edilir. Sistem her defasında doğru tahmin ettiği sonuçları alarak yoluna devam eder (Dietterich, 2000).

3.2.10 Düzenleştirme (regularization)

Makine öğrenmesi algoritmaları ile problem çözümünde karşılaşılan sorunlardan biri makinenin veri setini öğrenmeyi bırakıp ezberleyerek aşırı uyum (overfitting) sağlamasıdır. Bunun önüne geçmek için regresyon modeli bir takım teknikler ile geliştirilir. Bu teknikler arasında literatürde en çok kullanılanlara örnek olarak Ridge, Lasso ve Elastic Net verilebilir (Alpaydin, ve Bach, 2014).

3.2.10.1 Çıkıntı (ridge regression)

Bu teknik ile doğrusal regresyondaki maliyet fonksiyonuna beta katsayılarını sıfıra doğru düşürerek model ağırlıklarının düşmesini sağlayan bir düzenleştirme terimi eklenir. Bu modeli kullanmadan önce verinin ölçeklendirilmesi gerekebilir.

3.2.10.2 Lasso (least absolute shrinkage and selection operator regression)

Bu teknik ile Çıkıntı tekniğinde olduğu gibi maliyet fonksiyonuna farklı bir düzenleştirme terimi eklenir. Lasso tekniğinin farkı makine öğrenmesi modelindeki bazı özniteliklerin ağırlıklarını düşürmek hatta sıfır yapmaktır. Çıkıntı olarak özniteliklerden sadece birkaç tanesinin ağırlığının sıfırdan farklı olduğu ayrık (sparse) bir model verir (Şahinarslan, 2019).

3.2.10.3 Elastic net

Bu teknikte düzenleştirme terimi olarak Çıkıntı ve Lasso tekniklerinin bir karışımı olan terim, maliyet fonksiyonuna eklenir. Düzenleştirme teknikleri arasında Çıkıntı tekniğini tüm modeller için kullanılırken, az sayıda özniteliklerin model için daha verimli olacağı düşünülüyorsa Lasso ve Elastic net kullanılır (Şahinarslan, 2019).

3.2.11 Basit bayes (naive bayes) sınıflandırıcı

Basit Bayes (Naive Bayes) sınıflandırıcısı değişkenlerin birbirlerinden tamamen bağımsız olduğu varsayılan basit ama etkili bir sınıflandırma tekniğidir. Sınıflandırma yapılması istenen verilerin birbirlerinden bağımsız olmaları mümkün değil gibi gözükse

de bu varsayımın kullanılarak yapılan arařtırmaların iyi sonuçlar verdiđi ortaya çıkmıřtır (Rish, 2001). Uygulaması basit ve hızlı bir teknik olduđu için sınıflandırma problemlerinde ilk tercih edilen yöntemlerden biridir.

3.2.12 K-en yakın komřu (K-Nearest Neighbor (KNN))

K-En Yakın Komřu (KNN) algoritması etiketleme bilgisi bulunmayan gözlemlerin birbirlerine yakınlık derecesi göz önünde bulundurularak yapılan sınıflandırma işlemidir. Basit bir işlem gibi gözükse de makine öğrenmesi sınıflandırma problemleri için oldukça kullanışlı bir yöntemdir. Bu algoritmanın güçlü yanlarından bazıları; uygulamanın basit ve verimli olması, algoritmanın verinin dağılımı hakkında varsayım yapmaması ve eğitim sürecinin hızlı olmasıdır. Zayıf yönleri ise sınıflandırmanın yavaş yapılması, yüksek bilgisayar hafızası gerektirmesi ve veri setindeki kayıp değerlerin (missing value) işlem yükünü artırmasıdır.

Bu algoritmanın uygulama aşamasında öncelikle eğitim verisi kullanılarak sistem eğitilir. Eğitim setinde sınıflandırma bilgisi bulunan veriler mevcuttur. Eğitim seti verildikten sonra kullanıcı tarafından bir k değeri tespit edilir. Sistem öğrendiđi eğitim setindeki sınıfları göz önüne alarak yeni verilen gözlem verilerinden birbirine en yakın bulunan k tane komřu veriyi sınıflandırır. Verilerin birbirine olan yakınlıđını ölçmek için Öklid uzaklıđı, Jaccard Distance, Simple Matching Distance, Manhattan Distance gibi yöntemler kullanılır (Lantz, 2013).

3.2.13 Destek vektör makineleri (SVR)

Destek Vektör Makineleri basit ve yüksek performans veren öğrenme algoritmasıdır. Sınıflandırma için düzlem üzerindeki örnekler arasına sınır çizgisi çizilerek hiper düzlem oluşturulur. Sınır çizgisi grup üyelerine en uzak yerde olmalıdır. Hiper düzleme en yakın öğrenme eğrileri destek vektörler olarak adlandırılır. Doğrusal ve doğrusal olmayan SVR olarak ayrılmaktadır. Doğrusal SVR algoritmasında verileri ayırmak için sonsuz sayıda hiper düzlem oluşturulur ve hiper düzlemde maksimum hiper düzlem seçilir. Doğrusal olmayan SVR algoritmasında ise sınıflar doğrusal ayrılmadıđından dolayı veriler büyük bir alana aktararak kullanılır (Karakoyu ve Hacıbeyođlu, 2014) .

3.2.14 Lineer regresyon

Lineer regresyon iki ya da daha fazla değişken arasındaki ilişkiyi ölçmek için kullanılan metottur. En basit makine öğrenme modelidir. Bu algoritma neden ve sonuç arasında lineer ilişki olup olmadığını belirler. Eğitim kümesi kurularak hipotezdeki uygun parametre seçilir ve gelecekteki farklı veri girdilerine karşılık tahmin yapılır (Yılmaz vd., 2016).

3.2.15 Yapay sinir ağları (ANN)

Yapay Sinir Ağları insan beyninden yola çıkarak öğrenme, hatırlama, genelleme yapma yolu ile veri toplayarak yeni veri üretebilen bilgisayar yazılımıdır. Eldeki verilerden yola çıkarak genelleme yapmakta ve hiç görmediği veriler hakkında genellemelere göre karar verebilmektedir. Yapay Sinir Ağları en çok tahmin, sınıflama, veri ilişkilendirme, yorumlama ve filtreleme işlemlerinde kullanılmaktadır (Şahin, 2018).

Yapay Sinir Ağları modelleri tek katmanlı, çok katmanlı, ileri beslemeli ve geri beslemeli sinir ağları olarak dört grupta incelenir. Tek katmanlı ağlar sadece girdi-çıkıttan oluşur ve çıktı fonksiyonu doğrusaldır. Çıktı 1 (birinci sınıfa) ve -1 (ikinci sınıfa) değerlerini almaktadır. Çok katmanlı ağlar girdi katmanı, ara katman ve çıktı katmanı ile çalışır. İleri beslemeli ağlar girdi katmanı, gizli katman ve çıktı katmanı olarak düzenli katmanlardan oluşur. Bir katmandan sadece kendinden sonraki katmana bağ kurabilir. Geri beslemeli ağlar ise sadece kendinden sonraki katmana girdi verilmez kendinden önceki ve kendi katmanına da bağ kurabilir (Öztürk ve Şahin, 2018).

3.3 Performans Metrikleri

Makine öğrenmesi algoritmalarının performansları çeşitli metrikler kullanılarak değerlendirilmektedir. Bu metrikler arasından en yaygın kullanılanları R^2 , RMSE ve MAE performans metrikleridir. R^2 gerçek test değerleri ile algoritmaların çıkardığı sonuçların birbirine ne kadar uyumlu olduğunu gösteren bir metriktir. Bu değer 1'e ne kadar yakın ise algoritmalar o kadar başarılı sayılmaktadır. RMSE ve MAE metrikleri ise gerçek test değerleri ile algoritmaların çıktıları arasındaki hatayı ifade etmektedir.

Bu metrikler 0'a ne kadar yakın ise hata o kadar düşük olmakta ve algoritmalar o kadar başarılı sayılmaktadır. Kullanılan metriklere ait formüller aşağıda sunulmuştur.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.3)$$

3.4 Literatür Özeti

Huang ve Kua, PM_{2,5} konsantrasyonunu izlemek ve tahmin etmek için Evrişimli Sinir Ağı (CNN) ve Uzun/Kısa Süreli Bellek (LSTM) algoritmalarını birleştirmiştir ve bu algoritmaların karşılaştırmasını yapmak için dört ölçüm indeksi; Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hatası (RMSE), Pearson korelasyon Katsayısı ve Uyum İndeksi (IA) uygulamıştır. Sonuç olarak diğer makine öğrenmesi algoritmaları ile karşılaştırıldığında CNN-LSTM modelinin bu makalede en yüksek tahmin doğruluğuna sahip olduğu belirtilmiştir (Huang ve Kua, 2018).

Zhan vd., PM_{2,5} konsantrasyonları ile aerosol optik derinlik (AOD) ve meteorolojik koşullar gibi tahmin değişiklikleri arasındaki ilişkiyi incelemek için yeni bir makine öğrenmesi algoritması olan Coğrafi Olarak Ağırlıklı Gradyan Arıtma Makinesi (GW-GBM) algoritmasını geliştirmişler. Sonuç olarak Çin nüfusunun %95'inin ortalama yıllık PM_{2,5} konsantrasyonunun 35 mg/m³'ten fazla olduğu bölgelerde yaşadığı ve nüfusun %45'inin 100 gün boyunca PM_{2,5} >75 mg/m³'e maruz kaldığı tahmini yapılmıştır (Zhan vd., 2017).

Ayturan; Ankara İli, Keçiören İlçesi için PM_{2,5} konsantrasyonunu doğruluk oranları ile tahmin edebilmek için derin öğrenme algoritmalarından özellikle Geçitli Tekrarlayan Ünite (GRU) ve Devirli Sinir Ağları (RNN) algoritmalarını uygulayarak %83'e yakın bir model oluşturmuştur (Ayturan, 2019).

Lim vd., Güney Kore Seul'de $PM_{2.5}$ konsantrasyon seviyeleri için Mobil Örneklem Kullanım Regresyon (LUR) modellerini geliştirmişlerdir. LUR modelini oluştururken Doğrusal Regresyon (LR), Rastgele Orman (RF) ve Çoklu Makine Öğrenimi Birleştiren Yığınlanmış Topluluk (SE) algoritmalarını uygulamış ve karşılaştırmışlardır. Sonuç olarak SE algoritması ile en başarılı tahmin elde etmişlerdir (Lim vd., 2019).

Tamas vd., Batı Akdeniz'deki Korsika Adası'nın iki kentsel alanı için 24 saatlik ozon (O_3), azot dioksit (NO_2) ve partikül madde (PM_{10}) hava kalitesi konsantrasyonlarını tahmin etmekte makine öğrenmesi yöntemlerini uygulamışlardır. Çok Katmanlı Algılayıcı (MLP) tek başına kullanılmış daha sonra hiyerarşik kümeleme ve kendi kendini organize eden harita ve k-ortalımalı kümeleme algoritmaları uygulanmıştır. Sonuç olarak Korsika'da hava kalitesi tahmini için çalışmada sunulan modellerle operasyonel bir araç oluşturulmuştur (Tamas vd., 2016).

Deters vd. (2017), altı yıllık meteorolojik rüzgâr ve yağış seviyelerinden $PM_{2.5}$ konsantrasyonlarını tahmin etmek için makine öğrenmesi yöntemlerinden Artırma Ağaçları (Boosted Trees_BTs) ve Lineer Destek Vektör Makinesi (LSVM) algoritmalarını uygulamışlardır. Sonuç olarak $PM_{2.5}$ konsantrasyonlarını tahmin etmede makine öğrenmesine dayanan modellerin kullanılmasının önemli olduğunu belirtmişlerdir.

Gültepe (2019), Kastamonu İli için meteorolojik ve çevre uygulamalarında hava kirliliği tahmininde başarılı sonuç elde etmek için çeşitli makine öğrenmesi algoritmaları uygulamıştır. Tahmin modelleri için, Yapay Sinir Ağları (YSA), Rastgele Orman (Random Forset), k- En Yakın Komşu, Lojistik Regresyon, Karar Ağacı, Lineer Regresyon ve Basit Bayes yöntemlerini uygulamıştır. Sonuç olarak, YSA algoritması için doğru tahmin oranı %87, Rastgele Orman algoritması için doğruluk oranı %99 ve Karar Ağacı algoritması için doğruluk oranı %99 olarak belirtmiştir.

Akbulut ve Özcan (2019), Türkiye'deki 31 ilin SO_2 ve PM_{10} konsantrasyon tahmini için Yapay Sinir Ağları (YSA) ve Regresyon modelleri uygulamışlar ve karşılaştırmalarını yapmışlardır. İlk olarak 2012-2018 yılları arasında ölçülen PM_{10} bağımlı değişken olarak tanımlanmış ve sonuç olarak YSA modeli daha iyi uyum sağlayan algoritma

olarak seçilmiştir. 2019 yılı için PM_{10} konsantrasyon tahmini YSA yöntemi ile yapılmıştır.

Konya İli hava kirliliği tahmininde Yapay Sinir Ağları (YSA) algoritmasının uygulandığı çalışmada eğitim ve test periyotları süresince kolerasyon katsayısı sırasıyla 0,82 ve 0,70 olarak tespit edilmiştir (Kunt, 2007).




BÖLÜM IV

MATERYAL VE YÖNTEM

4.1 Çalışma Bölgesi ve Hava Kirliliği Verileri

4.1.1 Coğrafi konumu

Kayseri, İç Anadolu Bölgesinin güneyinde Orta Kızılırmak bölümünde yer almaktadır. Kuzeybatıda Yozgat, kuzeydoğuda Sivas, doğuda Kahramanmaraş, güneyde Adana, güneybatıda Niğde, batıda ise Nevşehir illeriyle çevrilidir. 37°45' ile 38°18' kuzey enlemleri ve 34°56' ile 36°58' doğu boylamları arasında yer almaktadır (Şekil 4.1). 16.917 km²'lik yüzölçümüne sahip Kayseri ilinin denizden yüksekliği 1054 m'dir (Kayseri İl Kültür ve Turizm Müdürlüğü, 2020).



Şekil 4.1. Kayseri kenti genel görünümü

Kent, eski kent merkezi etrafında örümcek ağı morfolojisine uygun nitelikte yayılmıştır (Şekil 4.1). OSB bölgesi geliştikçe kent bu bölgeye doğru lineer bir yayılma göstermektedir. Kentin kuzeyinde yer alan ve son yıllarda aktif olarak kullanılan hava alanına doğru kesintili kırsal yerleşimler bulunmaktadır. Kentin hava kalitesi düzeyinde yoğun konsantrasyon miktarlarının gözlemlendiği kent merkezi ve OSB civarında üç istasyon yer almaktadır. Bu istasyonlardan Hürriyet İstasyonu konut sahası olarak kentin yoğun yerleşim alanlarının bulunduğu bölgede yer almaktadır. Trafik istasyonu ise eski kentin merkezinin ve geleneksel ticaret merkezinin odağında ve günlük ihtiyaçlarına yönelik yaşayanların ve turistlerin uğrak noktası olduğu trafiğin en yoğun yaşandığı bölgede yer almaktadır.

4.1.2 Kent nüfusu

Kayseri, Türkiye'nin en kalabalık 15. şehri olup İç Anadolu Bölgesinin üçüncü büyük kenti ve sanayi merkezidir. Kayseri; Bünyan, Develi, Hacılar, İncesu, Kocasinan, Melikgazi, Pınarbaşı, Sarioğlan, Sarız, Tomarza, Yahyalı, Talas, Özvatan, Felahiye ve Yeşilhisar olmak üzere 16 ilçe ve 420 mahalleye sahiptir. İl nüfusu 2019-2020 Türkiye İstatistik Kurumu (TÜİK) verilerine göre 1.407.409'dur. TÜİK verilerine göre 2007-2019 yılı Kayseri nüfusu Çizelge 4.1'de mevcuttur. Nüfusun %50,13'ünü erkek, %49,87'sini kadın nüfus oluşturmaktadır (Çevre ve Şehircilik İl Müdürlüğü, 2019). Kayseri nüfusunun büyük çoğunluğu kent merkezinde yaşamaktadır. Altyapı hizmetlerinin büyük ölçüde tamamlanmış durumda olması, hızla gelişen eğitim kurumlarına sahip olması ayrıca ekonomik bakımdan önemli sanayi ve ticaret merkezi konumunda olması şehrin hızla göç almasına olanak sağlamaktadır (TÜİK, 2020).

Çizelge 4.1. 2007-2019 yıllarına göre Kayseri nüfusu (TÜİK)

Yıl	Kayseri Nüfusu	Erkek Nüfusu	Kadın Nüfusu
2019	1.407.409	705.545	701.864
2018	1.389.680	696.658	693.022
2017	1.376.722	689.595	687.127
2016	1.358.980	681.269	677.711
2015	1.341.056	672.828	668.228
2014	1.322.376	663.249	659.127
2013	1.295.355	649.851	645.504
2012	1.274.968	640.095	634.873
2011	1.255.349	631.165	624.184
2010	1.234.651	621.667	612.984
2009	1.205.872	607.022	598.850
2008	1.184.386	595.275	589.111
2007	1.165.088	584.656	580.432

4.1.3 İklim özellikleri

Kayseri ilinin birçok yerinde bozkır iklimi etkilidir. Yazlar sıcak ve kurak, kışlar soğuk ve kar yağışlıdır. Kayseri’de en sıcak günler Çizelge 4.2’de görüldüğü gibi Temmuz ve Ağustos aylarında ölçülür iken en soğuk günler aralık, ocak, şubat aylarında ölçülmektedir (Meteoroloji Genel Müdürlüğü, 2019).

Çizelge 4.2. Kayseri ilinin aylık ortalama sıcaklık ve yağış değerleri

KAYSERİ	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık	Yıllık
Ölçüm Periyodu (1931 - 2019)													
Ortalama Sıcaklık (°C)	-1.6	0.2	4.8	10.5	15.0	19.0	22.2	22.0	17.4	11.8	5.5	0.6	10.6
Ortalama En Yüksek Sıcaklık (°C)	4.1	6.2	11.4	17.6	22.5	26.8	30.6	30.7	26.5	20.4	13.0	6.4	18.0
Ortalama En Düşük Sıcaklık (°C)	-6.8	-5.1	-1.3	3.1	6.8	9.7	12.0	11.4	7.3	3.5	-0.9	-4.4	2.9
Ortalama Güneşlenme Süresi (saat)	3.0	4.0	4.8	6.2	8.2	10.3	11.8	11.3	9.1	6.7	4.8	2.9	83.1
Ortalama Yağışlı Gün Sayısı	12.7	11.5	13.0	12.6	13.0	8.6	2.3	1.8	3.7	7.5	8.8	12.1	107.6
Aylık Toplam Yağış Miktarı Ortalaması (mm)	35.9	35.8	42.4	51.3	51.6	40.2	10.7	8.8	14.6	28.1	32.2	37.6	389.2
Ölçüm Periyodu (1931 - 2019)													
En Yüksek Sıcaklık (°C)	18.0	22.6	28.6	31.2	34.2	37.6	40.7	40.6	36.0	33.6	26.0	21.0	40.7
En Düşük Sıcaklık (°C)	-32.5	-31.2	-28.1	-11.6	-6.9	-0.6	2.9	1.4	-3.8	-12.2	-20.7	-28.4	-32.5


Kayseri genel olarak bozkır bitki örtüsü ile kaplıdır. İlin yüksek kesimlerinde orman örtüsü görülse de toprak genel olarak çalılıklar ile kaplıdır. İlin güneyinde yer alan Toros Dağlarının olduğu bölgede karaçam, kızılçam, köknar, ladin ve meşe türleri hâkimdir (Kayseri İl Kültür ve Turizm Müdürlüğü, 2019).

4.1.4 Hava kalitesi

Kayseri; coğrafi konum olarak işlek bir noktada olması, hızlı sanayileşme, taşıt sayısındaki artış, yakıt kullanımı ve meteorolojik şartlar gibi nedenlerden dolayı hava kirliliğine yoğun olarak maruz kalmaktadır. Hava kirliliğini ölçmek ve strateji belirlemek için atmosferik kirleticiler konsantrasyonlarını izlemek, kirliliği analiz etmek ve kirlilik durumunu kamuoyuna açık ve anlaşılır şekilde sınıflandırmak gerekmektedir. Ülkemizde tüm dünyanın da kullandığı Hava Kalitesi İndeksi (HKİ) denilen sınıflama sistemi ile havadaki kirleticiler konsantrasyonlarına göre hava kalitesi için iyi, orta, kötü, tehlikeli vb. şekilde derecelendirilme yapılmaktadır (Kayseri 2019 ÇED Raporu, Çevre ve Şehircilik İl Müdürlüğü). Çizelge 4.3'te hava kalitesi derecelendirmesi mevcuttur. Kayseri'nin hava kalitesi ölçümü için belirlenen istasyon yerleri ve bakılan parametreler Çizelge 4.4'de belirtilmiştir. Kayseri için belirlenen üç istasyon bölgesinin hava kalite indeksi Şekil 4.2'de mevcuttur.

Çizelge 4.3. Ulusal Hava Kalite İndeksi kesme noktaları

İndeks	HKİ	SO ₂ [µg/m ³]	NO ₂ [µg/m ³]	CO [µg/m ³]	O ₃ [µg/m ³]	PM10 [µg/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



Şekil 4.2. Kayseri Hava Kalite İndeksi (Ulusal Hava Kalitesi İzleme Ağı, 2020)

Çizelge 4.4. Kayseri’de 2019 yılı hava kalitesi ölçüm istasyon yerleri ve ölçülen parametreler

İSTASYON YERLERİ	KOORDİNATLAR (ENLEM, BOYLAM)		HAVA KİRLETİCİLERİ					
			PM ₁₀	PM _{2.5}	NO ₂	SO ₂	O ₃	CO
HÜRRİYET (Revize)	38.714757	35.470575	X	X	X	X		X
KOCASİNAN (Yeni)	38.744597	35.418918	X		X	X		X
MELİKGAZİ (Yeni)	38.722883	35.518705	X	X	X	X		X
OSB (Revize)	38.740437	35.375453	X	X	X	X	X	X
TALAS (Yeni)	38.698954	35.553436	X		X	X	X	
TRAFİK (Revize, Eski Melikgazi)	38.717305	35.486887	X	X	X		X	X
Toplam Cihaz (Analizör) Sayısı			6	4	6	5	3	5

4.2 Örneklemeye Noktaları ve Örneklemeye Analizleri

Türkiye’de birçok ilde olduğu gibi Kayseri il genelinde zaman zaman hava kirliliği problem oluşturmaktadır. Hava kirliliğinin araştırılmasının yanında kirliliğin giderilmesi adına çözüm ortaya konulması önem arz etmektedir. Kayseri ilinde Ulusal Hava Kalitesi İzleme Ağı bünyesinde 2007 yılından itibaren anlık ve sürekli izleme ağına geçilmiştir (Kayseri İli 2018 Yılı Çevre Durum Raporu). Hava kalitesi düzeyini ölçmek amacıyla hava kalitesi Gözlem İstasyonları kurularak saatlik ortalama SO₂, PM₁₀, hava sıcaklığı, hava basıncı, nem, rüzgâr yönü ve rüzgâr hızı ölçülmektedir (Gültepe, 2019). Bu tez çalışmasının amacı, 2010-2018 yılları arasındaki PM₁₀ konsantrasyon değerleri kullanılarak bu alanda Makine Öğrenmesi Algoritmaları ile 2019 yılı için tahmin yapılması ve bu tahminlerin gerçek değerlerle karşılaştırılıp doğru bir tahmin yöntemi olup olmadığının belirlenmesidir. Bu tez çalışması için PM₁₀ konsantrasyon verileri Kayseri İli hava kalitesi ölçüm istasyonları olan Trafik, Hürriyet ve OSB istasyonlarından günlük ortalama veriler olarak temin edilmiştir.

Bu tez çalışmasında makine öğrenmesi algoritmalarından Destek Vektör Makinesi (Support Vector Machines), Rastgele Orman (Random Forest), k En Yakın Komşu (k Nearest Neighbor), Lineer Regresyon algoritmaları ve Yapay Sinir Ağları kullanılmıştır.

4.3 Mekansal Analiz

2010-2019 yılları arasında istasyon verilerinin yıllık ortalamaları ve mevcut analizlere göre yapılan tahminleri incelemek amacıyla Coğrafi Bilgi Sistemlerinden (CBS) yararlanılmıştır. CBS uygulamalar için veri toplama, saklama, sorgulama, ilişkilendirme, modelleme veya modelleme çalışmalarından elde edilen sonuçların görselleştirilmesinde yaygın olarak kullanılmaktadır (Ertürk vd., 2004; Ataol, 2010). Hava kirliliği değişiminin ortaya konulmasında CBS uygulamalarından mekânsal dağılımın analiz yöntemleri (Kriging ve IDW yöntemleri) sıklıkla kullanılmaktadır.

Bu çalışmada CBS yazılımlarından biri olan ArcGIS 10.6.1 yazılımı yardımıyla istasyonların yıllara göre değişen verilerinin kent üzerindeki mekânsal dağılımları IDW yöntemiyle analiz edilmiştir. IDW, birbirine yakın olan şeylerin birbirine uzak olandan daha benzer olduğunu varsayarak ölçülmemiş herhangi bir konum için tahmin

konumunu çevreleyen ölçülmüş değerleri kullanarak bir değer tahmin etmektedir (URL-10, 2020). IDW enterpolasyon yöntemiyle 2010, 2015 ve 2019 yıllarına ilişkin değişen veriler ortak lejand üzerinde görselleştirilerek yıllar arasındaki fark ortaya konulmuştur.



BÖLÜM V

BULGULAR VE TARTIŞMA

5.1 Makine Öğrenmesi Algoritmaları


Makine öğrenmesi algoritmaları kullanılarak PM_{10} konsantrasyonu tahmini metoduna ait sonuçlar Çizelge 5.1’de verilmiştir. Çizelgede, her bölgeye ait sonuçlar için diğer bölgelerdeki PM_{10} konsantrasyon değerleri kullanılarak tahmin modelleri kurulmuş ve 2019 yılı PM_{10} konsantrasyonu ile ilgili bölgedeki tahminine ait sonuçlar gösterilmiştir. Bu şekilde bir şehirdeki farklı bölgeler arasında mekânsal bağ kurularak istenen bir bölgedeki değerin tahmini yapılabilmektedir. Uygulanan algoritmalar ile veri setinde büyük veri ile çok sayıda özellik bulunuyorsa ve bunları yorumlayacak denklem ya da fonksiyon yok ise anlam çıkarmak veya çeşitli sebeplerden dolayı istasyonlarda ölçümlerin eksik olması, kayıp değerlerin olması durumunda veri setindeki kayıp değerler için o niteliğe ait ortalama değerlerle doldurulması sağlanmaktadır. Bunun için çözülmesi gereken problemi çözerken doğru veri ile algoritmayı beslemek çok önemlidir.

Sonuçlar incelendiğinde Trafik, Hürriyet ve OSB bölgesindeki istasyonlarda en iyi sonucun SVR algoritması tarafından üretildiği görülmektedir. En iyi sonuçlar Trafik bölgesi için SVR algoritması ile $R^2=0,85$, RMSE=17,57, MAE=10,17; Hürriyet bölgesi için SVR algoritması ile $R^2=0,73$, RMSE=34,91, MAE=24,61; OSB bölgesi için SVR algoritması ile $R^2=0,82$, MAE=21,62 ve ANN algoritması ile RMSE=41,59 olarak gözlemlenmiştir. Bununla birlikte diğer makine öğrenmesi algoritmaları da SVR algoritmasına oldukça yakın performans göstermişlerdir.


Çizelge 5.1. Makine öğrenmesi algoritmalarıyla PM₁₀ konsantrasyon tahmini deney sonuçları

		SVR	Lineer Regresyon	kNN	Random Foreset	ANN
TRAFİK	R ²	0,8534	0,8218	0,84	0,8377	0,8281
	RMSE	17,5746	20,4584	18,1333	18,3478	21,1978
	MAE	10,1744	11,5951	11,6919	11,9915	13,5875
HÜRRİYET	R ²	0,7326	0,7212	0,7185	0,7148	0,7178
	RMSE	34,9185	39,2278	36,5521	36,0552	39,0553
	MAE	24,6184	28,9708	27,0007	26,5406	30,5481
OSB	R ²	0,8261	0,7945	0,788	0,7911	0,8068
	RMSE	41,7104	43,1906	42,6345	42,7542	41,5974
	MAE	21,6296	23,3571	22,7533	22,187	23,1481


Üç bölge için PM₁₀ konsantrasyonlarının 2019 yılı için çalışılan algoritmalar sonucu elde edilen değerler ile gerçek değerlerin yıllık olarak karşılaştırılması Şekil 5.1’de, üç bölge için 2010-2019 yılları arası PM₁₀ konsantrasyonu aylık değişimi Şekil 5.2’de ve 2010-2019 yılları arası PM₁₀ konsantrasyonu değişimi Şekil 5.3’te verilmiştir.



Şekil 5.1. Algoritmalar sonucu ile gerçek değerlerin yıllık olarak karşılaştırılması




Şekil 5.1. (Devamı) Algoritmalar sonucu ile gerçek değerlerin yıllık olarak karşılaştırılması




Şekil 5.1. (Devamı) Algoritmalar sonucu ile gerçek değerlerin yıllık olarak karşılaştırılması



Hürriyet




Şekil 5.2. Hürriyet-Trafik ve OSB istasyonlarına ait 2010-2019 yılları arası PM₁₀ konsantrasyonu aylık değişimi




Şekil 5.2. (Devamı) Hürriyet-Trafik ve OSB istasyonlarına ait 2010-2019 yılları arası PM_{10} konsantrasyonu aylık değişimi

OSB



Şekil 5.2. (Devamı) Hürriyet-Trafik ve OSB istasyonlarına ait 2010-2019 yılları arası PM₁₀ konsantrasyonu aylık değişimi



Şekil 5.3. Hürriyet-Trafik ve OSB istasyonlarına ait 2010-2019 yılları arası PM₁₀ konsantrasyonu değişimi

Her üç bölge için sonuçlar incelendiği zaman, algoritmaların genel olarak doğru değerler üretebildikleri görülmektedir. Trafik bölgesi için, algoritmalar tanıma aşamasında olduğundan 2019 yılının ilk günlerinde algoritmaların hiçbirinin gerçek değerleri yakalayamadığı gözlemlenmiştir. Lineer Regresyon, Random Forest ve Yapay Sinir Ağı algoritmalarının gerçek sonuçlara göre yüksek ve düşük değerler ürettikleri ve genel olarak gerçek değerlere en uygun sonuçların SVR algoritması tarafından üretildiği görülmektedir. OSB bölgesi için yılın ilk ayları için algoritmaların tahminlerinin genel olarak düşük kaldığı ve ilerleyen aylarda sonuçların gerçek değerlere yaklaştığı gözlemlenmektedir. Algoritmaların hepsinin birbirine benzer sonuçlar ürettiği görülmektedir. Hürriyet bölgesi için genel olarak algoritmaların ya düşük veya da yüksek sonuçlar ürettiği görülmektedir. Bu algoritmalar içerisinde en iyi sonucun SVR algoritması tarafından elde edilebildiği de görülmektedir. SVR algoritması çok çeşitli verilerde daha verimli çalışmakta ve daha iyi sonuç vermektedir. En kötü sonucun da kNN algoritması tarafından elde edildiği görülmektedir. Çünkü kNN eğitim aşamasında en yakındaki örneklerle bakarak verileri almakta ve yetersiz veriye bakıldığı için öğrenimi daha yavaşlamaktadır.

Literatüre bakıldığında son yıllarda hava kirliliği üzerine çeşitli makine öğrenmesi algoritmaları kullanılarak farklı çalışmalar yapılmıştır. Fakat yapılan çalışmaların çoğunda daha az veri kullanılarak çalışmalar yapılmış ayrıca bölgesel bir tahminden ziyade gelecek tahmini yapılmıştır. Yapılan bu tez çalışmasına benzer algoritmalar ve hava kirliletiçi parametreler kullanılarak yapılan çalışmalardan biri olan Ashayeri vd., PM_{2.5} konsantrasyonlarını tahmin etmek için Chicago'daki farklı kentsel mahallelerdeki hava kalitesi verilerini kullanarak en etkili algoritmayı bulmak için dokuz farklı makine öğrenmesi algoritmasını test etmişlerdir. Sonuç olarak, yapılan bu çalışmaya benzer şekilde SVR algoritmasının test edilen en iyi algoritma olduğu sonucuna varmışlardır. SVR algoritması model performansını yıl boyunca %18,4 ve aylık veri kümeleri için %98,7'ye kadar arttırdığı belirtilmiştir (Ashayeri vd., 2020). Bu çalışmada tahmin edilen hava kalitesi parametresi ile aynı parametrenin kullanıldığı Choubin vd. tarafından yapılan çalışmada Barselona Eyaletindeki 75 istasyondaki yıllık PM₁₀ için tehlikeli alanları tahmin etmek adına Random Forest (RF), Torbalı Sınıflandırma ve Regresyon Ağaçları (Torbalı CART) ve Karışım Ayırım Analizi (MDA) gibi makine öğrenmesi algoritmaları kullanmışlardır. Sonuçlarda üç makine öğrenmesi modelinin de mükemmel sonuç (doğruluk: >%87 ve hassasiyet: >%86) verdiği belirtilmiştir. Torbalı CART ve RF modellerinin aynı ve MDA modeline göre daha yüksek performansa sahip olduğu belirtilmiştir (Choubin vd., 2019). Yapılan başka bir çalışmada, Avusturya Graz'daki COVID-19 kısıtlaması sırasında hava kalitesi iyileştirmelerini analiz etmek için bir makine öğrenmesi modeli geliştirilmiştir. Graz'daki beş ölçüm istasyonundan NO₂, PM₁₀ ve O₃ konsantrasyonları seçilmiş ve Rastgele Orman (RF) modeli için hedef değişken olarak kullanılmıştır. Makine öğrenmesi modellerinin konsantrasyonları tahmin etmede yüksek performans gösterdiği sonucuna varılmıştır. Kentin kısıtlama dönemlerinde ortalama konsantrasyon düşüşleri NO₂ ve PM₁₀ için sırasıyla %36,9-41,6 ve %6,6-14,2 olduğu ayrıca O₃ için %11,6-33,8'lik bir artış olduğu tahmini yapılmıştır (Lovric vd., 2020). PM₁₀ parametresi üzerine Avustralya'nın Moranbah maden kasabesindeki yapılan başka bir çalışmada, 2011 yılından beri PM₁₀ hava kalitesinin standartların üzerinde seyretmesinden dolayı ölçülen PM₁₀ konsantrasyonlarını modellemek ve meteorolojik olarak normalleştirmek için makine öğrenmesi algoritmalarından Gradyan Artırılmış Regresyon ve Rastgele Orman modelleri kullanılmıştır. Sonuçta en iyi performansı Rastgele Orman algoritmasının sağladığı belirtilmiştir (Mallet, 2020). Masood ve Ahmed (2020) yılında Delhi'de yaptıkları çalışmada bu çalışmada da kullanılan algoritmalarından SVR ve YSA algoritmalarını

kullanarak günlük PM_{2.5} konsantrasyonlarını tahmin etmişlerdir. Sonuç olarak YSA'nın (eğitim ve test için korelasyon değeri sırasıyla 0,856 ve 0,730) PM_{2.5} tahmini için SVR'den daha iyi tahmin doğruluğu gösterdiği belirtilmiştir (Masood ve Ahmed, 2020).

Çevre ve Şehircilik Bakanlığı'nın 81 ildeki hava kalitesi izleme istasyonlarından aldığı verilerle oranını tespit ettiği havadaki partikül maddeler (PM₁₀) “akciğerlere ulaşarak iltihaplanmaya ya da insanları çok olumsuz etkileyecek kalp ve akciğer hastalıklarına neden” olabilmektedir. Dolayısıyla bu partiküllerin havadaki oranı, kirliliğinin en önemli göstergelerinden biri olarak kabul edilmektedir. Ancak Türkiye'nin mevcut yönetmelik ve uygulamalarda hava kalitesi ölçümünde sağlıklı seviye olarak kabul ettiği değerler, Avrupa Birliği (AB) ve DSÖ'nün kabul ettiği sınır değerlerden çok daha yüksek olduğu belirtilmektedir. Dünya'yı ve ülkemizi esir alan koronavirüs salgını ile büyükşehirlere araç giriş-çıkışlarının kapatılması, sokağa çıkma yasakları, uçuşların durdurulması gibi önlemler hava kirliliği ile ilgili konuları gündeme getirmiştir. Ekosfer Derneği'nin hazırladığı “Virüsten Kaçarken İklim Krizine Yakalanmak” raporu, koronavirüs salgınında uygulanan sokağa çıkma yasaklarının hava kirliliğine etkisini ortaya koymuştur. Türkiye'deki beş kentte hava kirliliğine yol açan PM₁₀ ve NO_x (Azot oksit) konsantrasyonlarında kapanma dönemlerinde belirgin bir azalma olduğu ve hava kalitesinde iyileşme gözlenmiştir. Kayseri İli'nde koronavirüs salgını için uygulanan sokağa çıkma dönemlerine ait (Mart-Nisan-Mayıs ve Haziran aylarına ait) Çizelge 5.2'de verilen 2018-2020 arası PM₁₀ konsantrasyonlarında ciddi azalmalar olduğu görülmektedir. Özellikle eve kapanmanın ilk ayları olan Mart ve Nisan aylarında sırasıyla %29 ve %25 azalmalar meydana gelmiştir. Benzer şekilde Gujral ve Sinha tarafından yapılmış çalışmada, partikül madde ve yer seviyesindeki ozon gibi hava kirlleticilerine kısa süreli maruz kalma ile SARS-CoV-2 vakalar arasındaki ilişkiyi bulmak için topluluk tabanlı dinamik emisyon modeli (EDEM) ve genelleştirilmiş katkı modeli (GAM) algoritmalarını test etmişlerdir. Bu çalışma için vaka sayılarının yoğun olduğu Kaliforniya'nın Los Angeles ve Ventura ilçelerini seçmişlerdir. GAM, PM_{2.5}, PM₁₀ ve O₃'te sırasıyla 1 µ/m³, 1 µ/m³ ve 1 ppm'lik bir artışın %4.51 düşüş ile ilişkili olduğu belirtilmiştir. EDEM, eğitim ve test veri kümelerinde R² değeri sırasıyla %90,96 ve %79,16 olarak sonuçlanmıştır. EDEM, partiküller ile SARS-CoV-2 vakaları ile negatif ilişkiyi doğrularken O₃ pozitif ilişki gösterdiği sonucuna varılmıştır. GAM ile gözlemlenen pozitif ilişkinin istatistiksel olarak anlamlı olmadığı belirtilmiştir (Gujral ve Sinha, 2020).

Çizelge 5.2. 2018-2020 yılları Mart-Nisan-Mayıs ve Haziran aylarına ilişkin PM₁₀ değerleri


PM ₁₀ (µg/m ³)	Mart	Nisan	Mayıs	Haziran
2018	63,936	41,098	39,708	47,08
2019	46,606	39,906	40,382	34,19
2020	45,528	30,626	33,009	32,161

Yapılan bu tez çalışmasında Kayseri'deki günlük ortalama hava kirliliğinin PM₁₀ konsantrasyonu üzerinden tahminlenmesi ve hava kirliliğinin çevresel ve mekânsal modellenmesi amaçlanmıştır. Tahminleme modeli ile istasyonlar arasında birbirlerine bağımlılıklarına bakarak gelecek tahmini yapılmıştır. Bu amaçla 3 istasyondan 2010-2018 yılları arasında PM₁₀ konsantrasyonu verileri kullanılarak makine öğrenmesi algoritmaları (kNN SVR, RF, ANN, Lineer Regresyon) ile veriler eğitilmiş her bölgenin 2019 yılına ait tahmini, gerçek verileri verilmeden diğer bölgelerin 2019 verileri kullanılarak elde edilmiştir. Bu şekilde bölgesel bağımlılık elde edilerek geleceğe yönelik tahmin yapılmıştır. En iyi sonuçlar 3 istasyon için de SVR algoritması ile elde edilmiştir. Ayrıca algoritmaların tahmin sonuçları ile gerçek değerler karşılaştırıldığı zaman, tüm algoritmaların genel olarak iyi sonuçlar üretebildikleri ve gerçek değerlere yakın tahminlerde bulundukları görülmüştür. Elde edilen tahmini konsantrasyon sonuçlarının mekânsal dağılımı Coğrafi Bilgi Sistemi (CBS) ile sağlanarak arazi kullanım üzerinde hava kirliliğinin iyileştirilmesine yönelik mekânsal stratejiler oluşturulmuştur.

5.2 Mekansal Analiz Sonuçları

Çalışmada PM₁₀ değerine etkileyen unsurlar grafik haritalar ile analiz edilmiştir (Şekil 5.4). Bu analizler 2010-2019 yılı kent merkezinin nüfus yoğunluğu, sanayi sektörü, yakıt kullanımı ve trafik yoğunluğunun değişimi olarak ele alınmıştır. Kent merkezinin nüfus yoğunluğunun 2010 yılından 2019 yılına kadar giderek arttığı tespit edilmiştir. Büyükşehir statüsündeki bir kent için beklenen nüfus artışına yönelik bu değişimin hava kalitesinin değişimine etkisi istasyon verileri ile değerlendirilmiştir. Sanayi sektöründe 2016 yılına kadar sanayi tesis sayısında artış gözlenirken daha sonraki yıllarda yeni açılan sanayi tesisi sayısında bir azalma tespit edilmiştir. Yakıt kullanımı değişiminde ise 2015 yılı yakıt kullanımının en fazla arttığı yıl olarak belirlenmiştir. Taşıt

kullanımında ise 2015 ve 2016 yılında diğer yıllara oranla en yüksek artış gerçekleşmiştir.



Şekil 5.4. Kayseri kent merkezinin yıllara göre mevcut durum analizi

Kayseri ili Büyükşehir Belediyesi statüsündedir. 5216 Sayılı Büyükşehir Belediye Kanunu'nda Ek Madde 3'e göre statüsü köy olarak eskiden tabir edilen konut yerleşiminin yoğun olmadığı kırsal bölgeler köy yerine kırsal mahalle olarak ifade edilmektedir. Çalışma sırasında bu kırsal nitelikli ve konut ve trafik yoğunluğu oldukça düşük olan mahallelerin hava kalitesinde oluşturacağı konsantrasyon değerlerinin etkisi göz ardı edilecek nitelikte olduğundan uygulama alan sınırı dışında tutulmuştur. Buna göre oluşturulan çalışma alanı sınırı, kent statüsünde olan ve yoğun konut ve trafiğin bulunduğu bölgeleri içeren mahalle sınırları olarak belirlenmiştir.


Belirlenen sınır içerisinde istasyon çevresindeki mahallelerin nüfus yoğunluğu tespit edilmiş ve bu nüfus yoğunluğu ile istasyonların etkilenme potansiyeline yönelik bir orantı kurulmuştur. Çizelge 5.3'te istasyon çevresindeki mahallelerin 2020-2019 yılları arasındaki nüfus yoğunluk değişimi verilmiştir. Buna göre OSB istasyonunun yakın çevresindeki mahalleler (Keykubat, Alpaslan, Tınaztepe, Selimiye, Kocatepe, Anafartalar, 30 Ağustos, Sakarya, Yeni Mahalle, Anbar, Mimar Sinan Fatih

Mahalleleri), Hürriyet istasyonunun yakın çevresindeki mahalleler (Selçuklu, Esenyurt, Hürriyet, Osmanlı, Yeniköy, Esentepe, Selçuklu, Osman Kavuncu, Battalgazi, Çorakçılar, Karacaoğlu, Aydınlikevler, Altınoluk, Küçük Mustafa, Kemeraltı, Gülük, Şehit NazımBey Mahalleri) ve Trafik İstasyonunun yakın çevresindeki (Mimar Sinan Demokrasi, Köşk, Yıldırım Bayezid, Gültepe, Nurihas, Kılıçaslan, Melikgazi, Tacettin Veli, Seyitgazi, Camikebir, Hunat, Cumhuriyet, Kışıkapı Mahalleri) mahalleler sınıra dahil edilmiştir.

Çizelge 5.3. İstasyonların çevresindeki mahallelerin nüfus yoğunluğu değişimi

	OSB İstasyonu	Hürriyet İstasyonu	Trafik İstasyonu
2010	97880	139960	99386
2011	96860	153220	102620
2012	97880	169430	105330
2013	98190	171673	107769
2014	10022	174186	112652
2015	100829	153887	115804
2016	102426	175617	116074
2017	101639	175915	117887
2018	102984	181216	198907
2019	106786	185912	200746

Ancak hava kalitesi değişimi sadece nüfus değişimi ile ortaya konulamayacağı için çalışmada kent bazında yakıt, taşıt ve trafik parametrelerinin bölgesel analizi gerçekleştirilmiştir.



Şekil 5.5. 2010, 2015 ve 2019 yıllarına göre PM₁₀ hava kalitesi değişiminin mekânsal dağılımı

Şekil 5.5'e göre mekânsal değişimi izlenen 2010, 2015 ve 2019 yılları arasında PM₁₀ konsantrasyon miktarının en yüksek olan yılın 2015 yılı olduğu tespit edilmiştir. Analiz sonuçları konumsal değişim ve mevcut durum analizlerine göre incelenmiştir. Buna göre 2010 ve 2015 yılında kentin en eski yerleşim noktası olan Hürriyet ve Trafik İstasyonları yoğun bir hava kirliliği içinde bulunmaktadır. Hürriyet istasyonu bu yıllarda diğer tüm istasyonlardan daha fazla hava kirliliği etkisi altındadır. 2019 yılında ise bu yoğunluğun kent merkezinden OSB'ne doğru konum değiştirdiği görülmektedir. Bunun nedeni 2016 yılından sonra azalan yakıt ve taşıt kullanımının bu bölgede yer alan

istasyonlardaki (Hürriyet ve Trafik) konsantrasyon miktarlarında azalmaya neden olmasdır. Ayrıca 2016 yılından sonra kentte sanayi sektöründe yıllara göre yeni bir artışa geçilmiş olması OSB bölgesinde hava kirliliğini artırmış ve bu nedenle hava kirliliğinin odak noktası kent merkezinden OSB bölgesine konum değiştirmiştir.

Diğer bir etken olan Nüfus Artışı ise kent merkezinin doğunluğa ulaşmış olması nedeniyle kent merkezi dışında özellikle hava alanı ve kentin doğu bölgesine yönelmiştir. Bu nedenle nüfus artışının doğrudan mevcut istasyonlardaki etkisi diğer unsurlara göre daha azdır.

Yapılan bu çalışmaya benzer olarak Tayvan'da Chang vd., (2020) tarafından yapılan çalışmada görünür iki boyutlu topolojik haritada uzun süreli bölgesel $PM_{2.5}$ konsantrasyon tahmini için bir makine öğrenmesi modeli oluşturulmuştur. 25 istasyondan çeşitli zaman ölçeklerinde (yıllık, mevsimsel, saatlik) $PM_{2.5}$ konsantrasyon verilerini kullanmışlardır. Sonuç olarak nüfus ve trafik yoğunluğu ve mevsimsel değişikliklerin $PM_{2.5}$ konsantrasyon değişiminde etkisi olduğunu ortaya koymuşlardır. Makine öğrenmesi tekniklerinin $PM_{2.5}$ özelliklerini mükemmel özetleyebildiği ve hava kalitesi tahmin doğruluğunu arttırabildiğini belirtmişlerdir (Chang vd., 2020).

BÖLÜM VI

SONUÇLAR

Yapılan çalışma kapsamında;

- Hava kirliliği değişimini makine öğrenim algoritmalarına (kNN SVR, RF, ANN, Lineer Regresyon) göre yüksek doğrulukla tahmin etme,
- Elde edilen tahmin değerlerine göre mekânsal dağılımın CBS yardımıyla analizi ve mekanda alınacak hava kirliliğinin iyileştirilmesine ilişkin çevresel önlemlerin ve arazi kullanım stratejilerinin oluşturulması gerçekleştirilmiştir.

Bu kapsamda Kayseri İli Trafik, OSB, Hürriyet bölgeleri için 2010-2018 yılları arasındaki yıllık PM_{10} konsantrasyon verileri kullanılarak 2019 yılına ait hava kirliliği tahmini yapılmıştır. 3 istasyondan 2010-2018 yılları arasında PM_{10} konsantrasyonu verileri kullanılarak makine öğrenmesi algoritmaları (kNN SVR, RF, ANN, Lineer Regresyon) ile veriler eğitilmiş her bölgenin 2019 yılına ait tahmini, gerçek verileri verilmeden diğer bölgelerin 2019 verileri kullanılarak elde edilmiştir. Bu şekilde bölgesel bağımlılık elde edilerek geleceğe yönelik tahmin yapılmıştır. Bu amaçla makine öğrenmesi algoritmaları olan SVR, Random Forest, kNN, ANN algoritmaları tarafından üretilmiş olan tahmin modelleri kullanılmış ve model sonuçları karşılaştırılmıştır. Elde edilen sonuçlara göre hava kirletici tahmini için en yüksek performansı üç istasyon için de SVR algoritması vermiştir. Modeller karşılaştırıldığında ise en iyi performans Trafik bölgesi için SVR algoritması ($R^2=0.85$, $RMSE=17.57$, $MAE=10.17$) ile sağlanmıştır. Ayrıca algoritmaların tahmin sonuçları ile gerçek değerler karşılaştırıldığı zaman, tüm algoritmaların genel olarak iyi sonuçlar üretebildikleri ve gerçek değerlere yakın tahminlerde bulundukları görülmüştür. Uygulanan algoritmalar ile veri setinde büyük veri ile birlikte çok sayıda özellik bulunuyorsa ve bunları yorumlayacak denklem ya da fonksiyon yok ise anlam çıkarmak veya çeşitli sebeplerden dolayı istasyonlarda ölçümlerin eksik olması, kayıp değerlerin olması durumunda veri setindeki kayıp değerler için o niteliğe ait ortalama değerlerle doldurulması sağlanmaktadır. Bunun için çözülmesi gereken problemi çözerken doğru veri ile algoritmayı beslemek çok önemlidir.

Algoritmalar ile elde edilen tahmini konsantrasyon sonuçlarının CBS ile mekânsal analizi yapılarak konumsal değişim ve mevcut durum analizlerine göre inceleme yapılmıştır. Buna göre; 2010 ve 2015 yılında kentin en eski yerleşim noktası, nüfus ve taşıt yoğunluğu olan Hürriyet ve Trafik İstasyonları yoğun bir hava kirliliği içinde bulunmaktadır. 2016 yılından sonra ve 2019 yılında kentte sanayi sektöründe yıllara göre artışa geçilmiş olması OSB bölgesinde hava kirliliğini artırmış ve bu nedenle hava kirliliğinin odak noktasının kent merkezinden OSB bölgesine konum değiştirmiştir.

Kayseri İl'inde hava kirliliği kaynakları özellikle kış aylarında kırsal kesimin konutlarda ısınma amaçlı olarak yakılan kalitesiz kömür, motorlu taşıtlardan kontrolsüz olarak yayılan salımlar ve OSB bölgesinde faaliyet gösteren sanayi tesislerinin çıkardığı emisyonlardır. 2020 Mart ayından itibaren koronavirüs salgını için uygulanan sokağa çıkma dönemlerine kirlletici parametrelerden PM_{10} konsantrasyonunda azalma görülmesi hava kirliliğinin azalması için yapılabilecek düzenlemelerin olduğunu göstermektedir. Özellikle kırsal kesimlerde yoğun olarak kullanılan fosil yakıtların yerine doğalgaz ya da yenilenebilir enerji kaynaklarının kullanımının teşvik edilmesi, kentleşme ve düzenli yapılaşmanın bir plan dahilinde yapılması, yeşil alanların artırılması, sanayi tesislerinde emisyon değerlerine sıkı denetimler getirilmesi bu düzenlemeler arasında sıralanabilir. Yapılan bu çalışma, yüksek yoğunluklu kentlerin hava kalitesinin makine öğrenmesi algoritmaları ile modellenmesi ve hava kalitesini etkileyen arazi kullanımının sürdürülebilir planlanmasına ilişkin öneriler sunması ile literatüre katkı sağlamaktadır.

KAYNAKLAR

Analitis, A., Barratt, B., Green, D., Beddows, A., Samoli, E., Schwartz, J. and Katsouyanni, K. “Prediction of PM_{2.5} concentrations at the location of monitoring sites measuring PM₁₀ and NO_x, using generalized additive models and machine learning methods: A case study in London”, *Atmospheric Environment* 117757, 1352-2310, 2020.

Alpaydin, E. and Bach, F. Introduction to Machine Learning, *MIT Press*. 2014.

Altıkat A., Ekmekyapar, Torun F. ve Turan Bayram T., “Küresel kirlilik: Dünya, Avrupa Birliği ve Türkiye’de Hava Kirliliği Örneği”, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi* 27 (2), 134-149, 2011.

Akbulut, İ. ve Özcan, B., “Hava Kirliliği Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma”, *Kocaeli Üniversitesi Fen Bilimleri Dergisi* 3 (1), 12-22, 2020.

Akcan, N. ve Yeşilyurt, C., Hava Kalitesi İzleme Metodolojileri ve Örneklem Kriterleri, *T.C Sağlık Bakanlığı Refik Saydam Hıfzısıhha Merkezi Başkanlığı Çevre Sağlığı Araştırma Müdürlüğü*, Ankara, 2001.

Ashayeri, M., Abbasabadi, N., Heidarinejad, M. and Stephend, B. “Predicting intraurban PM_{2.5} concentrations using enhanced machine learning approaches and incorporating human activity patterns”, *Environmental Research* 0013-9351, 2020.

Ataol, M., “Burdur Gölü’nün seviye değişimleri”, *Coğrafi Bilimler Dergisi* 8 (1), 77-92, 2010.

Aydınlar, B., Güven, H. ve Kırksekiz, S., “Hava Kirliliği Nedir, Ölçüm ve Hava Kalitesi Modelleme Yöntemleri Nelerdir?”, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya, 2009.

Ayturan, Y. A., Derin öğrenme ile havadaki partikül madde konsantrasyonu tahmini, Yüksek Lisans Tezi, **KTO Karatay Üniversitesi Fen Bilimleri Enstitüsü**, Konya, 2019.

Bayram, H. “Türkiye’de hava kirliliği sorunu: Nedenleri, alınan önlemler ve mevcut durum”, **Toraks Dergisi** 1302-7808, 159-165, 2005.

Bayram, H., Dörtbudak, Z., Fişekçi, E.F., Kargın, M. ve Bülbül, B., “Hava kirliliğinin insan sağlığına etkileri, Dünyada, ülkemizde ve bölgemizde hava kirliliği sorunu”, **Dicle Tıp Dergisi**, 33, 2,(105-112).

Breiman, L. “Bagging predictors”, **Machine learning** 24 (2), 123-140, 1996.

Chang, F-J., Chang, L-C., Kang, C-C., Wang, Y-S. and Huang, A. “Explore spatio-temporal PM2.5 features in northern Taiwan using machine learning techniques”, **Science of the Total Environment** 139656, 2020.

Choubin, B., Abdolshahnejad, M., Moradi, E., Querol, X., Mosavi, A., Shamshirband, S. and Ghamisi, P. “Spatial hazard assessment of the PM10 using machine learning models in Barcelona, Spain”, **Science of the Total Environment** 134474, 2019.

Çevre ve Şehircilik İl Müdürlüğü, <https://kayseri.csb.gov.tr/kayseri-hakkinda-i-768>, 2019.

Demirarslan, O. K., “Hava kalitesi ve değerlendirme modelleme yaklaşımı“, **VII. Atmospheric Science Symposium**, İstanbul, 2015.

Deters, J. K., Zalakeviciute, R., Gonzalez, M. and Rybarczyk, Y. “Modeling PM_{2.5} urban pollution using machine learning and selected meteorological parameters”, **Journal of Electrical and Computer Engineering** 5106045, 14, 2017.

Dietterich, T.G., Ensemble Methods in Machine Learning, International Workshop on Multiple Classifier Systems, **Springer**, 2000.

Doreswamy, G. I., “Forecasting Air Pollution Particulate Matter (PM2.5) using machine learning regression models”, *Procedia Computer Science* 171, 2057-2066, 2020.

Elbir, T., Müezzinoğlu, A. and Bayram, A., “Evaluation of some air pollution indicators in Turkey”, *EnvironInt* 2000, 26:5-10, 2000.

Ertürk, A., Ekdal, A., Gurel, M., Yuceil, K. and Tanik, A. “Use of mathematical models to estimate the effect of nutrient loadings on small streams”, *Fresen. Environ, Bull.* 13 (116), 1361-1370, 2004.

Friedman, J. H. “Greedy function approximation: a gradient boosting machin”, *Annals of statistics* 1189-1232, 2001.

Geurts, P., Ernst, D. ve Wehenkel, L. “Extremely randomized trees”, *Machine learning* 63 (1), 3-42, 2006.

Gujral, H. ve Sinha, A. “Association between exposure to airborne pollutants and COVID-19 in Los Angeles, United States with ensemble-based dynamic emission model”, *Environmental Research* S0013-9351(20)31603-0, 2020.

Gültepe, Y., “Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme”, *Avrupa Bilim ve Teknoloji Dergisi* 16, 8-15, 2019.

Huang, C-J. and Kuo, P-H. “A Deep CNN-LSTM Model for Particulate Matter (pm2.5) Forecasting in Smart Cities”, *Sensors* 18 (2220), 2018.

James, G., Witten, D., Hastie, T. and Tibshirani, R., Statistical Learning: An Introduction to Statistical Learning, *Springer*, 2013.

Karakoyun, M. ve Hacıbeyoğlu, M. “Biyomedikal veri kümeleri ile makine öğrenmesi sınıflandırma algoritmalarının istatistiksel olarak karşılaştırması”, *DEÜ Mühendislik Fakültesi, Mühendislik Bilimleri Dergisi* 16 (48), 30-41, 2014.

Kayseri İli 2018 Yılı Çevre Durum Raporu, https://webdosya.csb.gov.tr/db/ced/icerikler/kayser-cdr_2018_son-20191028091140.pdf, 2018.

Kayseri İl Kültür ve Turizm Müdürlüğü, <https://kayseri.ktb.gov.tr/TR-54978/iklim-ve-bitki-ortusu.html>, 2019.

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W. and Liu, T.Y., “Lightgbm: A highly efficient gradient boosting decision tree”, **Advances in Neural Information Processing Systems**, <https://papers.nips.cc/paper/2017/hash/6449f44a102fde848669bdd9eb6b76fa-Abstract.html>, 2017.

Kumar, S., Mishra, S. and Singh, S.K., “A machine learning-based model to estimate PM2.5 concentration levels in Delhi’s atmosphere”, **Heliyon** e05618,2405-8440, 2020.

Kunt, F. Hava Kirliliğinin Yapay Sinir Ağları Yöntemiyle Modellemesi ve Tahmini, Yüksek Lisans Tezi, **Selçuk Üniversitesi Fen Bilimleri Enstitüsü**, Konya, 2007.

Kunt, F. ve Dursun, Ş. “Konya merkezinde hava kirliliğine bazı meteorolojik faktörlerin etkisi”, **Ulusal Çevre Bilimleri Araştırma Dergisi**, Sayı 1(1):54-61 (2018).

Kök, F. “Kentlerde hava kirliliğini önleyecek ya da azaltacak yöntem için verilerin toplanması ve değerlendirilmesi”, **Ulusal Çevre Bilimleri Araştırma Dergisi**, Sayı 1(3):145-157 (2018).

Lantz, B., Machine Learning, with R. Olton, **Packt Publishing Ltd.**, UK, 2013.

Lim, C.C., Kim, H., Ruzmyn Vilcassim, M.J., Thurston, G.D., Gordon, T., Chen, L-C., Lee, K., Heimbinder, M. and Kim, S-Y. “Mapping urban air quality using mobile sampling with low-cost sensors and machine learning in Seoul, South Korea”, **Environment International** 131, 105022, 2019.

Lovric, M., Pavlovic, K., Vukovic, M., Grange, S.K., Haberl, M. and Kern, R. “Understanding the true effects of the COVID-19 lockdown on air pollution by means of machine learning”, *Environmental Pollution* 0269-7491, 2020.

Ma, J., Ding, Y., Cheng, J.C.P., Jiang, F., Tan, Y., Gan, U.J.L. and Wan, Z., “Identification of hung impact factors of air quality on a national scale using big data and machine learning techniques”, *Journal of Cleaner Production* 118955, 2019.

Mao, W., Wang, W., Jiao, L., Zhao, S. and Liu, A., “Modeling air quality prediction using a deep learning approach: Method optimization and evaluation”, *Sustainable Cities and Society* 102567, 2210-6707, 2020.

Mallet, M.D. “Meteorological normalization of PM₁₀ using machine learning reveals distinct increases of nearby source emissions in the Australian mining town of Moranbah”, *Atmospheric Pollution Research* 1309-1042, 2020.

Masood, A. and Ahmad, K. “A model for particulate matter (PM_{2.5}) prediction of Delhi based on machine learning appro aches”, *Procedia Computer Science* 167, 2101-2110, 2020.

Mendoza, C.A., Teodoro, A., Freitas, A. and Fonseca, J., “Spatial estimation of chronic respiratory diseases based on machine learning procedures-an approach using remote sensing data and environmental variables in quito, Ecvador”, *Applied Geography* 102273, 2020.

Meteoroloji Genel Müdürlüğü, <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=KAYSERI>, 2019.

Müezzinoğlu, A., Hava Kirliliği ve Kontrolünün Esasları, *Dokuz Eylül Yayınları*, İzmir, 2000.

Okkaoğlu, Y., Akdi, Y. and Ünlü, K.D. “Daily PM₁₀, periodicity and harmonic regression model: The case of London”, *Atmospheric Environment* 117755, 2020.

Orloff, G. K., Kaplan, B. and Kowalski, P., “Hydrogen Cyanide in Ambient Air Near a Gold Heap Leach Field; Measured vs. Modeled Concentrations”, *Atmospheric Environment* 45 I(39), 7015-7025, 2011.

Öztürk, K. ve Şahin, M.E., Yapay Sinir Ağları ve Yapay Zeka’ya Genel Bir Bakış, *Recep Tayip Erdoğan Üniversitesi Mühendislik Fakültesi*, Rize, 2018.

Photphanloet, C. and Lipikorn, R. “PM10 concentration forecast using modified depth-first search and supervised learning neural network”, *Science of the Total Environment* 138507, 2020.

Ren, X., Mi, Z. and Georgopoulos, P.G. “Comparison of Machine Learning and Land Use Regression for fine scale spatiotemporal estimation of ambient air pollution: Modeling ozone concentrations across the contiguous United States”, *Environment International* 105827, 2020.

Rende, F. Ş., Bütün, G. ve Karahan, Ş., “Derin öğrenme algoritmalarında model testleri: Derin testler”, *10. Ulusal Yazılım Mühendisliği Sempozyumu*, 2017.

Rish, I. “An empirical study of the naive Bayes classifier”. *IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence*, 2001.

Sağlar, E., İzmir ili hava kirliliğinin alansal ve zamansal olarak analizi, Yüksek Lisans Tezi, *Atatürk Üniversitesi Fen Bilimleri Enstitüsü*, Erzurum, 2019.

Swetapadma, A. and Yadav, A. “A Novel Decision Tree Regression- Based Fault Distance Estimation Scheme for Transmission Lines”, *IEEE Transactions on Power Delivery* 32 (1), 234-245, 2017.

Şahin, E., Makine Öğrenme Yöntemleri ve kelime kümesi tekniği ile istenmeyen E-posta/ E-posta sınıflaması, Yüksek Lisans Tezi, *Hacettepe Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, 2018.

Şahin, F., Işık, G., Şahin, G. and Kara, M.K. “Estimation of PM₁₀ levels using feed forward neural networks in Iğdir, Turkey”, *Urban Climate* 100721, 2212-0955, 2020.

Şahinarslan, F. V., Makine Öğrenmesi Algoritmaları ile Nüfus tahmini: Türkiye Örneği, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, 2019.

Tamas, W., Notton, G., Paoli, C., Nivet, M-L. and Voyant, C. “Hybridization of Air Quality Frecasting Models Using Machine Learning and Clustering: An Original Approach to Detect Pollutant Peaks”, *Aerosol and Air Quality Research* 16, 405-416, 2016.

TÜİK (Türkiye İstatistik Kurumu), <https://www.tuik.gov.tr/>, 2020.

Türkeş, M., Sümer, U.M. ve Çetiner, G., Küresel İklim Değişikliği ve olası etkileri, *Çevre Bakanlığı, Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi Seminer Notları*, 7-24, ÇKÖK Gn.Md., Ankara, 2000.

Tosun, E., Türkiye’nin 2009-2016 yılları arasındaki hava kalitesi verilerinin değerlendirilmesi, Yüksek Lisans Tezi, *Hacettepe Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, 2017.

Ulusal Hava Kalitesi İzleme Ağı, <http://index.havaizleme.gov.tr/Station/StationInfo/50>, 2020.

URL1, iglesiasevda.wordpress.com, 2019.

URL2, cevreportal.com, 2019.

URL3, <http://laboratuvar.cevre.gov.tr/>, 2019.

URL4, www.epa.gov/yyn/scram, 2019.

URL5, yesilist.com, 2019.

URL6, http://sim.cbs.gov.tr/STN/STN_Report/DataBank, 2020.

URL7, <https://www.dw.com/tr/g%C3%BCndem/s-10201>, 2020.

URL8, www.birgün.net, 2020.

URL9, iklimhaber.org/, 2020.

URL10, <https://pro.arcgis.com/en/pro-app/latest/help/analysis/geostatistical-analyst/how-inverse-distance-weighted-interpolation-works.htm>, 2020.

Vesilind, P.A., Mogan, S.M. and Heine, L.G., Introduction to Environmental Engineering, Çev. Dr. İsmail Toröz, **TDK Bilim**, Ankara, 2011.

Yeşilyurt, C. ve Akcan, N., Hava Kalitesi İzleme Metodolojileri ve Örneklem Kriterleri, Refik Saydam Hıfzıssıhha Merkezi, Ankara, 2001.

Yılmaz, M., Kanıt, R., Erdal, M., Yıldız, S. ve Bakış, A. “Bina bakım onarım ödeneklerinin etkin kullanımı maksadıyla ihale bedelini etkileyen faktörlerin yapay sinir ağları ve lineer regresyon yöntemleri ile belirlenmesi”, **Politeknik Dergisi** 19 (4), 461-470, 2016.

Yücedağ, C. ve Kaya, L.G., “Hava kirleticilerin bitkilere etkileri”, **Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, 7(1):67-74(2016).

Zhan, Y., Luo, Y., Deng, X., Chen, H., Grieneisen, M.L., Shen, X., Zhu, L. and Zhang, “Spatiotemporal prediction of continuous Daily PM2.5 concentrations across China using a spatially explicit machine learning algorithm”, **Atmospheric Environment** 155, 129-139, 2017.

ÖZ GEÇMİŞ

Nuray Şaşı tarihinde’da doğdu. İlk, orta ve lise öğrenimini’da tamamladı. 2010 yılında girdiği lisans programını Harran Üniversitesi Çevre Mühendisliği Bölümü’nden 2014 yılında tamamlayarak mezun oldu. 2018-2019 yılı Bahar döneminde Niğde Ömer Halisdemir Üniversitesinde yüksek lisans öğrenimine başladı. O tarihten itibaren yüksek lisans öğrenimini devam ettirmektedir.



