



**KTO KARATAY  
ÜNİVERSİTESİ**

**T.C.  
KTO Karatay Üniversitesi  
Fen Bilimleri Enstitüsü**

**ELEKTRİK VE BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
TEZLİ YÜKSEK LİSANS PROGRAMI**

**DERİN ÖĞRENME İLE HAVADAKİ PARTİKÜL MADDE  
KONSANTRASYONU TAHMİNİ**

**Yasin Akın AYTURAN**

**KONYA**

**Ocak 2019**

DERİN ÖĞRENME İLE HAVADAKİ PARTİKÜL MADDE  
KONSANTRASYONU TAHMİNİ

Yasin Akın AYTURAN


KTO Karatay Üniversitesi Fen Bilimleri Enstitüsü

Elektrik ve Bilgisayar Mühendisliği Ana Bilim Dalı  
Yüksek Lisans Programı

Yüksek Lisans Tezi

*Ocak, 2019*

Fen Bilimleri Enstitü Onayı

  
Fen Bilimleri Enstitüsü Müdür  
Prof. Dr. Hüseyin Bekir Yıldız

Bu tezli yüksek lisans tezinin yapılması gereken bütün gerekliliklerinin yerine getirdiğini onaylıyorum.

Anabilim Dalı Başkanı  
Dr. Öğr. Üyesi H. Oktay ALTUN



Yasin Akın AYTURAN tarafından hazırlanan DERİN ÖĞRENME İLE HAVADAKİ PARTİKÜL MADDE KONSANTRASYONU TAHMİNİ başlıklı bu çalışma 14.01.2019 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jüri tarafından tezli yüksek lisans tezi olarak kabul edilmiştir.

  
Tez Danışmanı

Dr. Öğr. Üyesi H. Oktay ALTUN

  
Tez Yardımcı Danışmanı

Dr. Öğr. Üyesi F. Didem TUNÇEZ

Jüri Üyeleri

Başkan: Prof. Dr. Şükrü DURSUN

Üye: Dr. Öğr. Üyesi H. Oktay ALTUN

Üye: Dr. Öğr. Üyesi Ali ÖZTÜRK

## Tez Bildirimi

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orjinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu bildirir aksi bir durumda aleyhime doğabilecek tüm hak ve kayıplarını kabullendiğimi beyan ederim.

Ocak-2019

Yasin Akın AYTURAN



## Özet

### DERİN ÖĞRENME İLE HAVADAKİ PARTİKÜL MADDE KONSANTRASYONU TAHMİNİ

Yasin Akın Ayturan

KTO Karatay Üniversitesi,

Fen Bilimleri Enstitüsü,

Elektrik ve Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi

Tez Danışmanı: Dr. Öğr. Üyesi H. Oktay ALTUN

Tez Yardımcı Danışmanı: Dr. Öğr. Üyesi F. Didem TUNÇEZ

Ocak 2019

Partikül madde ( $PM$ ), kimyasal bileşimi ve fiziksel özellikleri değişiklik gösteren, sağlığa zararlı hava kirleticilerden biridir. Dünya Sağlık Örgütü (WHO) tarafından, kanser yapıcı bir hava kirletici olarak kabul edilmektedir. Havadaki  $PM$  boyutları da farklılık göstermektedir. Genel olarak, aerodinamik çap açısından sınıflandırılırlar. Kaba taneceklerin aerodinamik çapı 2,5-10  $\mu m$  olarak kabul görmektedir. 10  $\mu m$ 'den büyük tanecekler ise çok kaba partiküller olarak adlandırılmaktadır. Partikülün ince yapısı olan ve çapı 2,5  $\mu m$ 'den küçük olan tozların solunum sisteminde akciğerlerin yapısında bulunan alveollere kadar ulaşabilmesi ve solunum sistemine karıştığı kabul edilmektedir. Bu da canlıların yaşam kalitesini bozmakta hatta kanser oranlarında artışa sebep olduğu kabul edilmektedir.  $PM$  kirliliğinin zararlı etkileri dikkate alındığında, bu kirleticinin gelecek konsantrasyonlarının belirlenmesi, zararların önlenmesi açısından büyük önem taşımaktadır. Bu çalışma ile havadaki  $PM$  kirliliğinin derin öğrenme yöntemi kullanılarak tahmin edilmesi amaçlanmaktadır. Geçmiş yıllara ait  $PM$  konsantrasyon verileri, meteorolojik faktörler, havadaki diğer kirleticilerin konsantrasyonları da dikkate alınarak tahmin kabiliyeti yüksek bir model oluşturulacaktır. Bu tez çalışmasında, gelecekteki  $PM_{2,5}$  konsantrasyonlarını daha yüksek doğruluk oranları ile tahmin etmek için derin öğrenme yöntemi kullanılmıştır. Çalışma kapsamında veriler Çevre ve Şehircilik Bakanlığı'nın hava kalitesi izleme istasyonlarından temin edilmiştir. Çalışma için Ankara İli, Keçiören İlçesinde yer alan hava kalitesi izleme istasyondan alınan veriler kullanılmıştır. Bu çalışmada makine öğrenmesinin alt sınıfı olan derin öğrenme algoritmaları kullanılmış ve özellikle geçitli tekrarlayan ünite (GRU) ve devirli sinir ağları (RNN) kombinasyonu ile kısa süreli tahmin performansı %83'e yakın bir model oluşturulmuştur.

**Anahtar kelimeler:** Derin öğrenme, modelleme, partikül madde

## Abstract

### FORECASTING OF PARTICULATE MATTER CONCENTRATION WITH DEEP LEARNING METHOD

Yasin Akin AYTURAN

KTO Karatay University,

The Graduate School of Natural and Applied Sciences,  
Master of Science Thesis in Electrical and Computer Engineering

Advisor: Asst. Prof. H. Oktay ALTUN

Co-Advisor: Asst. Prof. F. Didem TUNÇEZ

January 2019

Particulate matter (*PM*) is one of the pollutants harmful to health, whose chemical composition and physical properties different from each other. It is accepted as a cancerous air pollutant by the World Health Organization (WHO). There are different *PM* with various dimensions in the air. In general, they are classified in terms of aerodynamic diameter. The aerodynamic diameter of coarse particles is accepted as 2.5-10  $\mu\text{m}$ . Particles larger than 10  $\mu\text{m}$  are called very coarse particles. It is accepted that powders with fine structure of particle and smaller than 2.5  $\mu\text{m}$  in diameter can reach up to the alveoli in the respiratory system and interfere with the respiratory system. As a result, the life quality of living beings is disrupted and even the increase of cancer rates is possible. When considering the harmful effects of *PM* pollution, the prediction of future concentrations of this pollutant is of great importance in terms of prevention of damages. With this study, it is aimed to estimate *PM* pollution in the air using deep learning methods. According to *PM* concentrations belonging to previous years, meteorological factors and the concentrations of other pollutants found in the air, a prediction model with high accuracy was developed. In this thesis study, deep learning has been used to obtain the accuracy rate of future *PM*<sub>2.5</sub> concentrations with higher estimates. The data has been obtained from the Air Quality Monitoring Stations of the Ministry of Environment and Urbanization. Data obtained from the air quality monitoring station in Keçiören District of Ankara Province were used for the study. In this study, deep learning algorithms, which are the subclass of machine learning, has been used and especially with gated recurrent unit (GRU) and recurrent neural network (RNN) combination, has been formed as close to 83%.

**Keywords:** Deep learning, modelling, particulate matter

## Teşekkür

Çalışmalarım boyunca her türlü fedakarlığı gösteren ve bana her konuda destek olan sabırlı eşim Zeynep Cansu Ayturan ve biricik oğlum Doruk Ayturan'a, moral ve motivasyon konusunda beni hiç yalnız bırakmayan bütün aileme, birbir çalışarak fikirleriyle projeyi yöneten ve katkılarıyla beni yönlendiren tez danışmanım Dr. Öğr. Üyesi Hüseyin Oktay Altun'a ve yardımcı danışmanım Dr. Öğr. Üyesi Fatma Didem Tunçez'e, hava kirliliği hakkında tecrübelerinden faydalandığım Prof. Dr. Şükrü Dursun'a ve bütün bu süreçte bana arkadaşlık yapan Emre Dalkılıç'a ve Serbay Acar'a teşekkür ederim.

Ayrıca bana çalışma alanı sunan KTO Karatay Üniversitesi'ne, Konya Teknik Üniversitesi Mühendislik ve Doğabilimleri Fakültesi'ne bunun yanında tezi tamamlamamda beni destekleyen şirketim Pardus Ajans ve Hermes Reklam'a teşekkürlerimi sunarım.

Yasin Akın AYTURAN  
Ocak-2019

# İçindekiler

Tez Bildirimi	iv
Özet	v
Abstract	vi
Teşekkür	vii
Şekil Listesi	x
Tablo Listesi	xii
Simge ve Kısaltmalar	xiii
<b>1 Giriş ve Çalışmanın Amacı</b>	<b>1</b>
<b>2 Hava Kirliliği</b>	<b>4</b>
2.1 Hava Kirliliği Kaynakları	4
2.2 Başlıca Hava Kirleticileri	5
2.2.1 Gaz Hava Kirleticileri	5
2.2.2 Kükürt İçeren Kirleticiler	5
2.2.3 Azot İçeren Kirleticiler	6
2.2.3.1 Diğer Kirleticiler	6
2.2.4 Partikül Hava Kirleticileri	7
2.2.4.1 Partikül Boyut Dağılımı	8
2.2.4.2 Partikül Mekanikleri	10
2.2.4.3 Partikül Kaynakları	12
2.2.4.4 Partiküllerin Etkileri	13



<b>3</b>	<b>Yapay Zeka</b>	<b>15</b>
3.1	Makine Öğrenmesi	16
3.1.1	Derin Öğrenme	17
3.1.1.1	Derin Öğrenmenin Tarihçesi	18
3.1.1.2	Derin Öğrenmenin Mühendislik Alanlarında Kullanımı	19
3.1.1.3	Derin Öğrenme ile Hava Kalitesi Modellemesi	19
3.1.1.4	Önceki Çalışmalardan Örnekler	24
<b>4</b>	<b>Veri Temini ve Metot</b>	<b>26</b>
4.1	Çalışma Alanı ve İstasyon Yeri	26
4.1.1	Çalışma Alanının İklimsel Özellikleri	28
4.2	Veri Temini	29
4.3	Veri Setinin Hazırlanması	30
4.4	Veri Normalleştirilmesi	32
4.5	Modelin Belirlenmesi ve Uygulanması	33
4.6	Model Sonuçları	36
4.7	Sonuçlarının Değerlendirilme Kriterleri	42
<b>5</b>	<b>Sonuçlar</b>	<b>43</b>
<b>6</b>	<b>Ekler</b>	<b>45</b>
	<b>Kaynaklar</b>	<b>50</b>
	<b>Özgeçmiş</b>	<b>56</b>

# Şekil Listesi

2.1	Partikül terimleri ve boyut dağılımları	9
2.2	Partikül madde boyut dağılımı gösterimi	10
2.3	Partikül toplama mekanizmaları	12
3.1	Yıllara göre yapay zekâ, makine öğrenmesi ve derin öğrenmenin gelişimi	19
3.2	RNN blok yapısı	21
3.3	LSTM blok yapısı	22
3.4	GRU blok yapısı	23
4.1	Ankara İl ve Keçiören İlçe Haritası	26
4.2	Keçiören hava kalitesi izleme istasyon yeri	27
4.3	Örnek bir hava kalitesi izleme istasyonu	28
4.4	Keçiören İlçesi aylara göre sıcaklık ve yağış değişim grafiği	29
4.5	Verilerin çekilip bulut ortamına atılması	31
4.6	Verilerin isimlendirilmiş örneği	31
4.7	Hava kirliliği zaman serisi grafikleri	32
4.8	Normalize edilmiş verilerin örnek satır görüntüsü	33
4.9	Model akış şeması	34
4.10	Modelin yapısı	35
4.11	Modelden elde edilen eğitim ve test kayıpları	36
4.12	Bir saat sonraki hava kirliliği tahminleri için regresyon eğrisi	37
4.13	Bir saat sonraki gerçek ve tahmini değerlerin karşılaştırması	38
4.14	İki saat sonraki hava kirliliği tahminleri için regresyon eğrisi	39

4.15 İki saat sonraki gerek ve tahmini deęerlerin karřılařtırması	40
4.16 Ü saat sonraki regresyon eęrisi	41
4.17 Ü saat sonraki gerek ve tahmini deęerlerin karřılařtırması	42



# Tablo Listesi

2.1	Havada bulunan partikül terminolojisi	8
3.1	Derin öğrenme kullanılarak geliştirilen hava kalitesi modelleme çalışmaları	25
4.1	Ankara'da bulunan hava kalitesi istasyon verilerinin STD değerleri	27
4.2	Keçiören Hava Kalitesi İzleme İstasyonu ham verileri örneği	30
4.3	Uygulanan modellerin karşılaştırması	34

# Kısaltmalar

Kısaltmalar	Açıklama
<i>UOB</i>	Uçucu organik bileşikler
<i>PM</i>	Partikül madde
$\mu m$	Mikrometre
$\mu g$	Mikrogram
$m^3$	Metreküp
<i>HF</i>	Hidroflorik asit
<i>H<sub>2</sub>S</i>	Hidrojen sülfür
<i>NH<sub>3</sub></i>	Amonyak
<i>HC<sub>s</sub></i>	Hidro karbonlar
<i>CO<sub>2</sub></i>	Karbondioksit
<i>SO<sub>x</sub></i>	Kükürt oksitler
<i>SO<sub>2</sub></i>	Kükürt dioksit
<i>SO<sub>3</sub></i>	Kükürt trioksit
<i>NO</i>	Nitrojen oksit
<i>NO<sub>x</sub></i>	Nitrojen oksitler
<i>NO<sub>2</sub></i>	Nitrojen dioksit
<i>SO<sub>4</sub><sup>2-</sup></i>	Sülfat
<i>H<sub>2</sub>O</i>	Su
<i>H<sub>2</sub>S</i>	Hidrojensülfür
<i>H<sub>2</sub>SO<sub>4</sub></i>	Sülfürik asit

# Kısaltmalar

Kısaltmalar	Açıklama
$HNO_3$	Nitrik asit
$CH_4$	Metan
$HCl$	Hidrojen klorür
$LSTM$	Uzun-kısa dönem hafıza
$STDL$	Mekânsal-zamansal derin öğrenmeye
$DAL$	Derin hava öğrenmesi
$RNN$	Devirli sinir ağları
$CNN$	Kıvrımlı sinir ağları
$EVS$	Açıklanmış varyans regresyon skoru
$RMSLE$	Kök ortalama karekök logaritmik sapması
$RMSE$	Kök ortalama karekök sapması
$STD$	Standart sapma
$MAE$	Ortalama mutlak hata
$pH$	Hidrojenin gücü
$AI$	Yapay zeka

# Semboller

**Simgeler** **Açıklama**

*Hg* Cıva

*As* Arsenik

*Pb* Kurşun

*Cd* Kadmiyum



# 1 Giriş ve Çalışmanın Amacı

Dünya nüfusunun artmasıyla birlikte, artan enerji kullanımı, endüstrinin gelişimi, şehirleşme ve ısınmak için kullanılan yakıt şekli hava kirliliğine sebep olmakta ve dünyamıza tehdit oluşturmaktadır. Atmosferin doğal halinde bulunmayan toz, duman, gaz, koku ve saf olmayan su buharı gibi kirleticiler, canlıların sağlığını olumsuz yönde etkilemektedir ve bu kirleticilerin belirli seviyenin üzerine çıkması, “hava kirliliği” olarak tanımlanmaktadır. Hava kirliliği bir problemdir ve hava kalitesi seviyesinin yükseltilebilmesi için kirletici kaynaklarının sebep olduğu kirliliğin değerlendirilmesi, denetim altına alınması ve gelecekteki durumunun tahmini ile mümkün olabilmektedir [1].

Atmosfere doğrudan salınan kirleticilere birincil kirleticiler denir. Bunlar; kükürt-dioksit ( $SO_2S$ ), hidrojen sülfür ( $H_2S$ ), azotoksit (NO), azotdioksit ( $NO_2S$ ), karbonmonoksit (CO), karbondioksit ( $CO_2$ ), hidrojen florür (HF), partikül madde (PM)’den oluşur [2]. Partikül maddeler (PM) ise havada çeşitli formlarda bulunmaktadırlar. Bunlar; İnce tozlar: Büyük zerreciklerdir. Kömür, kül ve çimento üretiminden, taşınmasından, mekanik atölyelerden, kum yıkama ve püskürtme tesislerinden yayılmaktadır. Kimyasal dumanlar; buharların süblimleştirilmesi ve damıtma işlemleri sırasında ortaya çıkan metal oksitlerdir. Kimyasal buharlar; herhangi bir buharın kimyasal olarak yoğunlaşması neticesinde meydana gelen sıvı zerreciklerdir. Sülfürik asit ( $H_2SO_4$ ) buharının oluşması buna örnek olarak verilebilir. Yanma dumanları; karbonlu maddelerin yarı yanma reaksiyonları ile yanması sonucu meydana gelirler. Örneğin HC, SOx, NOx ve organik asitler oluşabilmektedir. Spray ise sıvı maddenin atomlarına ayrılması sonucu oluşan sıvı zerreciklerdir [3].

Partikül madde (PM), rüzgâr, deniz ve volkanlar gibi doğal kaynaklardan veya doğada insan kaynaklı ortaya çıkan ve bir gaz içerisindeki ince katı veya sıvı maddelerin oluşturduğu çökelmeyen karışım olarak tanımlanır ve literatürde genel olarak gaz içerisinde dağılmış ve gazla sarılmış 10  $\mu m$ ’den daha küçük çaplı sıvı veya katı parçacıklarından oluşan çok fazlı sistem olarak geçer [4, 5]. Hava ortamında takip edilmek için belirlenen bazı PM boyutları vardır. Genel olarak, aerodina-



mik çap açısından sınıflandırılırlar. Kaba taneciklerin aerodinamik çapı 2,5-10  $\mu\text{m}$ ; ince taneciklerin ise; 0,1-2,5  $\mu\text{m}$ 'dir. 10  $\mu\text{m}$ 'den büyük tanecikler ise çok kaba partiküller olarak adlandırılmaktadır. Partikül maddelerin boyutu, onların havada asılı kalma süresini belirlemektedir.  $PM_{10}$  ve  $PM_{2,5}$ , sırasıyla aerodinamik çapı 10 ve 2,5  $\mu\text{m}$ 'dan küçük partiküllerin kütlelerini temsil etmektedir.  $PM_{2,5}$  atmosferde haftalarca ya da aylarca kalabilirken;  $PM_{10}$  birkaç saat içerisinde çökerek atmosferden uzaklaşabilmektedir [6].  $PM$  konsantrasyonu, endüstriyel ortamlarda  $\mu\text{g}/\text{m}^3$  veya  $\text{mg}/\text{m}^3$  olarak, ofis binalarında ve endüstriyel temiz odalarda ise adet/ $\text{m}^3$  olarak ifade edilir [7].

$PM$ 'ler özellikle akciğerlerin derin noktalarına kadar soluma yoluyla gidebilirler ve sağlık açısından ciddi zararlı etkileri vardır.  $PM_{10}$  kirleticileri üst solunum yollarında filtre edilebilirken,  $PM_{2,5}$ 'in bronşlara kadar girebilmektedir ve tehlikesi çok daha fazladır.  $PM_{2,5}$  akciğerler içerinden kana karışabilme yetisine bile sahiptir.  $PM$  kaynaklı hava kirliliği solunum yolu rahatsızlıkları, nefes almada zorluk, öksürük, akciğer fonksiyonlarında azalma, kalp krizi, astım krizi, prematüre doğum gibi birçok hastalığı sebebiyet verebilir ve bu sebeplerden kaynaklı ölüm vakaları olduğu tespit edilmiştir [8]. Partikül maddelerin fiziksel özellikleri yanında kimyasal kompozisyonu da sağlık açısından oldukça önemlidir. Partikül maddeler cıva, kurşun, kadmiyum gibi ağır metaller ile kanserojen kimyasalları bünyelerinde bulundurabilmekte ve sağlık üzerinde önemli tehdit oluşturabilmektedirler. Bu zehirli ve kanser yapıcı kimyasallar, nemle birleşerek aside dönüşmektedir. Bunun yanı sıra kurum, uçucu kül, benzin ve dizel araç egsoz partikülleri kanser yapıcı maddeler içerdiğinden bunların uzun süre solunması da kansere sebep olabilmektedir.

$PM$  kirliliğinin tüm zararlı etkileri dikkate alındığında, bu kirleticinin gelecek konsantrasyonlarının belirlenmesi ve zararların önlenmesi açısından büyük önem taşımaktadır. Bu çalışma ile havadaki  $PM_{2,5}$  kirliliğinin derin öğrenme yöntemleri kullanılarak tahmin edilmesi amaçlanmaktadır. Bu sayede  $PM$  kirliliğine karşı önceden önlem almak, kirlilik kaynaklarını belirleyerek azaltılmaları için çalışmalar yapmak mümkün olabilecektir. Geçmiş yıllarda yoğunlukla çalışılan yapay sinir ağları kullanılarak oluşturulan düşük tahmin oranına sahip, güvenilirliği tartışmalı hava kirliliği tahmin modelleri dikkate alındığında, bu tez çalışması ile yüksek tahmin kabiliyetine sahip bir model oluşturularak, bu alandaki eksikliklerin giderilmesi mümkün olabilir.

Türkiye'de günlük ölçümde  $PM_{10}$  için sınır değer 100  $\mu\text{g}/\text{m}^3$  olarak belirlenmiştir.  $PM_{2,5}$  için Türkiye henüz limit değerler oluşturulmamıştır ancak Avrupa Birliği 25  $\mu\text{g}/\text{m}^3$  sınır değer olarak kabul etmektedir. WHO'ya göre 10  $\mu\text{g}/\text{m}^3$  sınır değer olarak belirlenmiştir. Bu limit değerler ve ölçüm istasyonu sonuçları karşılaştırıldığında Ankara Keçiören Hava Kalitesi İstasyon verilerinde tespit edilen  $PM$  konsantrasyonlarının zaman zaman limitleri aştığı görülmektedir. Tüm

bu sebepler dikkate alındığında  $PM$  konsantrasyonun ileriye yönelik doğruluğu yüksek tahminin yapılması oldukça önemlidir. Derin öğrenme yöntemi kullanılarak yapılan diğer bütün çalışmalarda yüksek oranda doğruluk oranı ile sonuçlar elde edilmiştir bu sebeple derin öğrenmenin bu tezin amacı için de en doğru tahmini oluşturacak yöntem olduğu düşünülmektedir.

Derin Öğrenme ile modelleme yapılırken ilk olarak giriş ve çıkış vektörleri belirlenmelidir. Ardından transfer fonksiyonu belirlenmeli, ağırlıklandırma seçilmeli ve gizli katman sayısı belirlenmelidir. Ağırlıklandırmalar belirlenmeli ve modelin öğrenme algoritması seçilmelidir. Derin öğrenme modelinin genel yapısı giriş ve çıkış katmanlarını kapsamaktadır. Sinir ağındaki her katman sayısal bir değerle ağırlıklandırılmaktadır. [9]. Giriş - çıkış nöronları, öğrenme şekli, ağ yapısı, aktifleştirme fonksiyonu tipi ve eğitim algoritması gizli katmandaki nöronlardan etkilenir [10,11]. Gizli katmandaki nöron sayısını belirlemek için farklı ağırları eğitmek ve test verilerindeki hatalara yaklaşmak gereklidir [11].

Ocak 2017 - Kasım 2018 tarihlerine ait Ankara Keçiören Hava Kalitesi İzleme İstasyonu'ndan elde edilen  $PM_{2,5}$  konsantrasyon verileri ve meteorolojik faktörleri, havadaki diğer kirleticilerin konsantrasyonları da dikkate alınarak tahmin kabiliyeti yüksek bir model oluşturulmuştur. 1, 2 ve 3 saat sonraki  $PM_{2,5}$  kirliliği GRU+RNN metoduyla tahmin edilmiştir. GRU metodunda uzun ve kısa süreli hafıza blokları kullanılarak gelecek tahmini yapılmaktadır. RNN yönteminde ise tek aktifleştirme fonksiyonlu daha basit bir hücre yapısı kullanılmaktadır. Bu tez çalışması için uygun derin öğrenme metodu olarak bu iki yöntemin arka arkaya kullanıldığı metot seçilmiştir. Bu çalışma sonucunda  $R^2$  değerleri 1 saat için 0,832, 2 saat için 0,709 ve 3 saat için 0,611 olarak bulunmuştur. Bu değerlere bakıldığında modelin özellikle kısa süreli tahmin performansının daha iyi olduğu görülmektedir.

Bu tez çalışması; literatür araştırması, veri temini, metot ve sonuç kısmından oluşmaktadır. Bölüm 2'de hava kirliliği, başlıca hava kirleticileri ve  $PM$  ile ilgili önemli bilgiler verilmiştir. Bölüm 3'te yapay zeka, makine öğrenmesi ve derin öğrenme açıklanmış, ve Bölüm 3.1.1.4'te önceki çalışmalardan örnekler verilmiştir. Bölüm 4'de verilerin düzenlenmesi, model oluşturulması, model sonuçları, sonuçların değerlendirilmesi detaylı olarak gösterilmiştir. Bölüm 5'te ise bu tez çalışmasının katkıları anlatılmış ve elde edilen sonuçlar yorumlanmıştır.

## 2 Hava Kirliliđi

Atmosferde gaz, duman ve toz gibi farklı formlarda bulunabilen hem insan kaynaklı hem de dođal yollarla atmosfere salınan kirleticilerin yol açtıđı zararlar hava kirliliđi olarak tanımlanmaktadır [1]. Hava kirliliđinin önlenmesi ve canlıların sađlıđına etki eden problemlerin ortadan kaldırılması oldukça önemlidir. Hava kirliliđinin özellikle sanayi devriminden sonra önemi anlaşılmaya başlanmıř. 21. Yüzyılda artan nüfus ile de azaltılması ve önlenmesiyle alakalı çalıřmalar hız kazanmıřtır [12].

### 2.1 Hava Kirliliđi Kaynakları

Bařlıca hava kirliliđi kaynakları dođal ve antropojenik (dođada insanođlunun neden olduđu etkiler) olarak iki sınıfta incelenebilir. Dođal kaynaklar volkanik patlamalar, okyanuslar, orman yangınları ve kum fırtınalarıdır. Özellikle volkanik patlamaların yüksek miktarlarda partikül madde ile kükürtdioksit ( $SO_2$ ), hidrojen Sülfür ( $H_2S$ ) ve metan ( $CH_4$ ) gibi gazların salınımına neden olduđu bilinmektedir. Özellikle bu gazlar ve partiküller havada uzun süre kalabilirler. Orman yangınları da önemli dođal hava kirliliđi kaynaklarından biridir. Orman yangınları kül, duman, hidrokarbonlar, karbonlu bileřikler ve azot oksitler gibi bileřiklerin oldukça fazla miktarda atmosfere salınmasına sebep olur. Kum fırtınaları ise yaydıkları yüksek miktardaki partikül madde konsantrasyonları ile evleri ve endüstrileri ciddi olarak etkiler. Okyanuslar ise aerosolların salınımına sebep olarak korozyon problemlerine sebebiyet verebilir. Bunun yanı sıra yeřil bitkiler hidrokarbonların bařlıca kaynađıdır [12,13].

Antropojenik hava kirliliđi kaynakları ise endüstriyel tesisler, termik santraller ve kiřisel kaynaklardır. Endüstriyel tesisler üretim prosesleri sırasında saf malzemeleri kullanır ve hava kirliliđine katlı sađlarlar. Bunların bařlıcaları madenlerden kaynaklanan partikül madde ve  $SO_2$ , kimya endüstrisinden kaynaklanan  $HCl$ ,  $HF$ ,  $H_2S$ ,  $NO_x$ ,  $NH_3$ ,  $HCs$  ve  $UOB$  gibi kirleticiler, metal endüstrisinden  $Hg$ ,  $As$ ,  $Pb$ ,  $Cd$  gibi uçucu metaller salınabilir. Termik santraller elektrik üretimi için ciddi miktarlarda enerjiye ihtiyaç duyaralar. Kömür'ün yanması sonucu yüksek konsant-

rasyonlarda  $CO_2$ , azot ve kükürt oksitlerin atmosfere salınımı gerçekleşir. Bununla birlikte evlerin bacaları ve taşıtlar gibi kişisel kaynaklar da hava kirliliğine katkıda bulunurlar [12, 13].

## 2.2 Başlıca Hava Kirleticileri

Hava kirleticileri gaz ve partikül olmak üzere iki farklı grupta incelenirler. Gaz formunda olan kirleticiler genellikle kükürt ve azot içeren kirleticilerden oluşmaktadır. Partikül formunda olan kirleticiler kendi içlerinde aerodinamik çaplarına göre sınıflandırılırlar. Aşağıda atmosferde bulunan başlıca hava kirleticileri başlıklar altında sıralanmıştır:

### 2.2.1 Gaz Hava Kirleticileri

Gaz hava kirleticileri normal sıcaklık ve basınçta gaz formunda bulunan kirleticilerin yanı sıra oda sıcaklığında katı veya sıvı formda olan kirleticilerin buharlarını da kapsar. Bu gaz kirleticiler içerisinde en önemlileri karbon monoksit, hidrokarbonlar, kükürt, ozon ve azot içeren bileşiklerdir [14].

### 2.2.2 Kükürt İçeren Kirleticiler

Kükürt oksitler ( $SO_x$ ) ve hidrojen sülfür ( $H_2S$ ) başlıca kükürt içeren kirleticiler olarak bilinirler.  $H_2S$  salınımları  $SO_x$  ile kıyaslandığında çok daha düşük miktarlardadır [15].  $SO_x$ 'in başlıca kaynakları elektrik üretim tesisleri, petrol rafinerileri, taşıma ve endüstriyel tesislerdir.  $SO_x$ , içerisinde birçok oksitli bileşik barındırır ve bunlarının en önemlisi Kükürt dioksit ( $SO_2$ )'tir [15]. Neredeyse bütün fosil yakıtlar kükürt içerirler ve yanma sonucunda  $SO_x$  salınımına sebebiyet verirler. Bazı petrol yakıtlarının katalitik reaksiyonları sonucu  $H_2S$  oluşumu görülür. Ayrıca doğal gaz çıkarımı sırasında da  $H_2S$  salınımı meydana gelir [16].

Atmosferde özellikle  $SO_2$  öncü madde olarak oksijenle reaksiyona girerek oldukça zararlı olan sülfat ( $SO_4^{2-}$ ) formunu oluşturur.  $SO_3$  ise  $H_2O$  ile reaksiyon vererek sülfürik asit ( $H_2SO_4$ ) oluşumuna neden olur ve asit yağmurlarına katkı sağlar. Asit yağmurları su ortamlarının pH yapısını bozarak ekosisteme zarar vermesinin yanı sıra, bazı yapılarda da hasar oluşumuna sebebiyet verir. Havada yüksek konsantrasyonlarda kükürt oksit bulunması nefes problemlerinin başlıca sebebi olarak görülür. Bunun yanı sıra  $H_2S$  ve bazı organik kükürt içeren bileşiklerin yüksek

konsantrasyonlarda koku oluşumuna sebebiyet vermeleri de halk sağlığı açısından sorun teşkil etmektedir [9].

### 2.2.3 Azot İçeren Kirleticiler

Azot oksitler ( $NO_x$ ) birçok farklı hareketsiz kaynaktan atmosfere salınırlar ve azot oksit (NO), azot protoksit ( $N_2O$ ) ve azot dioksit ( $NO_2$ ) ana türlerindedir. Özellikle NO atmosferde daha istikrarlı oranlarda bulunur. Azot oksitlerin başlıca kaynağı fosil yakıtlar ve endüstriyel atıkların yanmasıdır. Atmosfere salınan  $NO_x$  konsantrasyonu yakıt içerisindeki azot miktarına ve yakma cihazının özelliklerine göre değişim göstermektedir. Yüksek yanma sıcaklıkları ve yanma ünitesindeki basıncın  $NO_x$  konsantrasyonlarını arttırdığı tespit edilmiştir [15].

Azot oksitler aynı kükürt oksitler gibi atmosferde su ile istenmeyen reaksiyonlara girerek nitrik asit ( $HNO_3$ ) oluşumuna sebebiyet verir ve asit yağmurlarının diğer bileşenini oluşturur. Bununla birlikte  $NO_2$  akciğerlere zarar vererek solunum rahatsızlıklarına sebebiyet verir. Ayrıca atmosferde organik bileşiklerle reaksiyona girerek ozon oluşumunu tetikler, bu olay fotokimyasal sis oluşumunun başlıca sebebidir. Atmosferik ozon ciğerlerdeki dokulara zarar vererek solunum yolu problemlerine sebep olur [15]. Amonyak ise genellikle besi hayvancılığı ve bu hayvanların atıklarından kaynaklanır. Büyük hayvanlardan kaynaklanan üre ve kümes hayvanlarından kaynaklanan ürik asit amonyak emisyonlarını artırır. Amonyak konsantrasyonunun çok fazla olması bitkilerin köklerindeki azot miktarlarını etkileyebilir [16].

#### 2.2.3.1 Diğer Kirleticiler

Kükürt ve azot içeren kirleticiler dışında havada uçucu organik bileşikler (benzen, tolüen ve kısilen), karbon monoksit (CO), hidrojen klorür (HCl) gibi kirleticilere de bulunur. Uçucu organik bileşikler genellikle metan ( $CH_4$ ) içermeyen hidrokarbonları, halokarbonları ve oksijenetleri içinde barındırır. Özellikle hidrokarbon grubu azot ile girdiği reaksiyonlardan dolayı daha büyük öneme sahiptir [16]. Bu kirleticiler gün ışığında azot oksitlerle reaksiyon vererek foto-kimyasal oksidanların oluşumuna sebep olurlar [17]. Bunun yanı sıra uçucu organik bileşikler havada bulunan diğer zararlı yan ürünlerle beklenmedik etkileşimlere girerek daha farklı ürünlerin oluşumunu da tetikleyebilirler [18].

Bununla birlikte uçucu organik bileşikler bazı sağlık problemlerine de sebebiyet verebilir. Örneğin, göz, burun ve soluk borusu tahribatı, kanser, baş ağrıları, böbrek ve ciğer rahatsızlıkları, kusma, sinir sistemi problemleri, baş dönmesi

gibi rahatsızlıklar maruziyetin dozuna göre deęişebilir [19]. Karbon monoksit ( $CO$ ) ise yakıtların yanması sırasında karbondioksitle birlikte aıęa ıkar ve kanda oksijen tařınmasını etkileyen toksik zelliklere sahiptir. Atmosferin byklę dřnldęnde karbon monoksit ( $CO$ ) konsantrasyonları ok dřk seviyededir ancak yeterli havalandırmanın olmadıęı durumlarda ciddi saęlık sorunlarına sebep olabilir [16].  $HCl$  zellikle nitrik asit ve slfrik asitin etkisiyle deniz tunun deklorlanması sonucunda atmosfere verilir. Bunun yanı sıra bazı yanma reaksiyonlarından da atmosfere salınabilir. Genel olarak ok dřk konsantrasyonlarda bulunurlar ve yaęmurda asitleřmeye sebep olabilirler [16].

#### **2.2.4 Partikl Hava Kirleticileri**

Atmosferde bulunan partikl kirleticiler birincil veya ikincil ya da katı veya sıvı olabilirler. Bu kirleticiler atmosfere birok farklı yolla girer ve ıkarlar. Atmosferde bulunan partikl hava kirleticileri terminolojik olarak Tablo 2.1'de verilmiřtir. Ařaęıda atmosferik partikllerin boyutları ve mekanikleri, kaynakları, evre ve insan saęlığına etkileri detaylıca anlatılmaktadır.


<b>Partikülün Adı</b>	<b>Tanımı</b>	<b>Boyutları</b>
Toplam askıda partikül maddeler	Havada bulunan tüm partikül kirleticileri kapsar.	Boyut sınırlaması yok
Partikül madde ( <i>PM</i> )	Genellikle aerodinamik çaplarına göre 10 $\mu\text{m}$ ( $PM_{10}$ ) ya da 2.5 $\mu\text{m}$ ( $PM_{2,5}$ ) partikülleri temsil eder.	10 $\mu\text{m}$ veya 2.5 $\mu\text{m}$
İnce partiküller	Genellikle birkaç $\mu\text{m}$ 'dan küçük partikülleri temsil eder.	< 2.5 $\mu\text{m}$ > 0.2 $\mu\text{m}$
Ultra ince veya nano partiküller	0.2 $\mu\text{m}$ 'dan küçük partikülleri temsil eder.	< 0.2 $\mu\text{m}$
Aerosol	Havada bulunan katı ve sıvı tüm partikülleri temsil eder.	Boyut sınırlaması yok
Kum	Genellikle mekanik işlemler sonucu oluşan en büyük partikül maddeleri temsil eder.	Boyutlar duruma göre belirlenir.
Toz	Kumlara göre daha küçük boyutlarda olan ve mekanik işlemler sonucu oluşan partikülleri temsil eder.	< 1 $\mu\text{m}$
Duman	Tamamlanamayan yanma sonucu oluşan, karbon ve yoğunlaşmış uçucuların karışımıdır.	< 1 $\mu\text{m}$

Tablo 2.1: Havada bulunan partikül terminolojisi [16]

#### 2.2.4.1 Partikül Boyut Dağılımı

Partiküller çoğunlukla çapları ile tanımlanırlar ve belirli bir çaptaki partikül miktarı hava kirliliği açısından büyük öneme sahiptir [20]. Partikül çapına göre bazı genel terimlerin dağılımları Şekil 2.1 de verilmiştir. Hava kirliliğine sebebiyet veren partiküllerin genellikle  $\mu\text{m}$  boyutlarında olduğu tespit edilmiştir. Özellikle boyut-

ları 10  $\mu\text{m}$ 'dan daha fazla olan parçacıklar kum gibi büyük boyutludur. İnsan saçının yaklaşık 50-110  $\mu\text{m}$  arasında değiştiği dikkate alınrsa küçük partiküllerin boyutları hakkında fikir sahibi olunabilir. Çok küçük partiküllerin boyutları 1  $\mu\text{m}$ 'dan daha düşüktür, duman ve is bu gruba örnek olarak verilebilir [20].



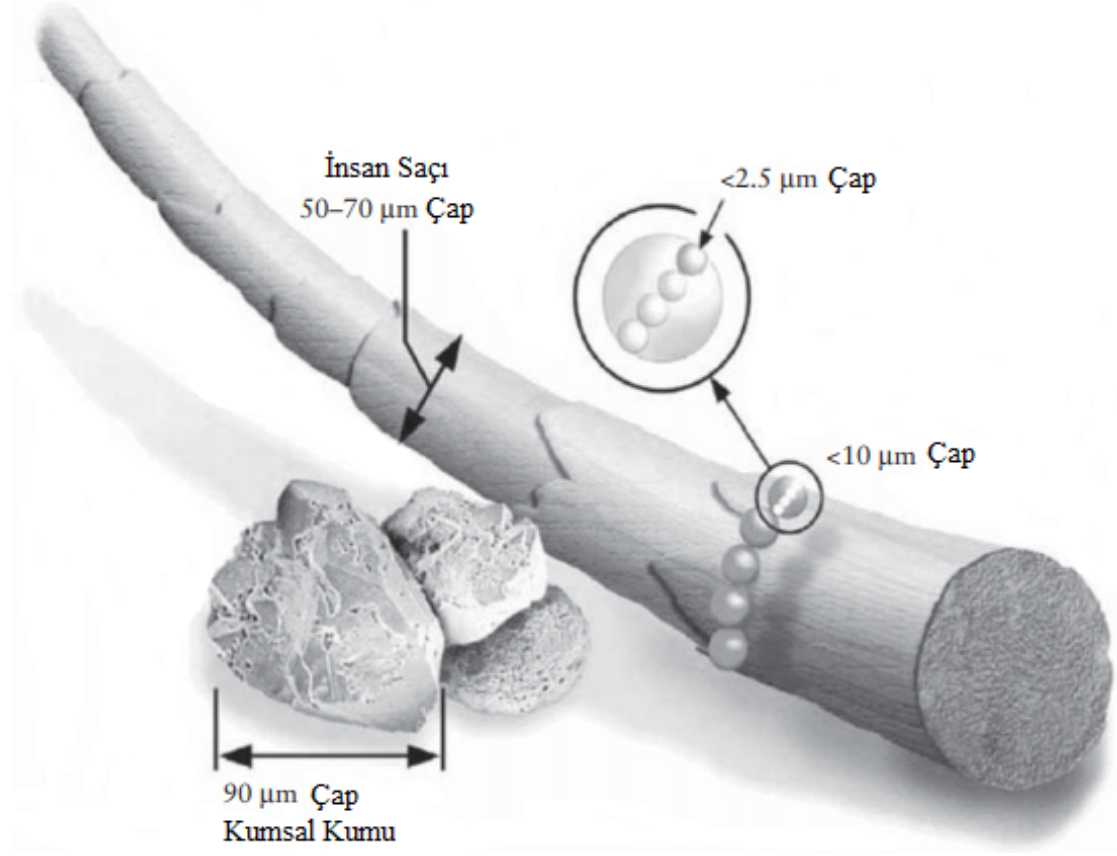
Şekil 2.1: Partikül terimleri ve boyut dağılımları [20]

Atmosferde bulunan partiküllerin boyutları, filtrasyon ile karakterize edilebilirler. Hava numuneleri alınarak filtrasyon işlemine tabi tutulduklarında, numunelerde bulunan partiküllerin miktarları ve boyut dağılımları belirlenebilir. Filtrasyon işlemi sonrası yapılan incelemelerde partikül boyut özellikleri belirlenebilmesine rağmen özellikle şekil olarak farklı tipte olan partiküller için aerodinamik çapla birlikte ışık saçma çapları da dikkate alınmalıdır. Aerodinamik çap, yoğunluğu  $1000 \text{ kg/m}^3$  olan küresel partikülün çapı olarak tanımlanır. Işık saçma çapı ise belli miktarda ışığı yayan bir küresel partikülün çapı olarak tanımlanır. Bununla birlikte çoğu partikül kendine özgü bir yoğunluğa ve şekle sahip olduğundan dolayı bu dağılım her zaman kolay olmamaktadır [16].

Atmosferde bulunan partikül kirleticilerinden en önemlileri partikül madde (PM) olarak adlandırılan kirleticilerdir. Bu kirleticiler aerodinamik çaplarına göre boyutlandırılırlar. Genellikle  $PM_{10}$  (çapı 10  $\mu\text{m}$  ile 2,5  $\mu\text{m}$  arasında olan partiküller) ve  $PM_{2,5}$  (çapı 2,5  $\mu\text{m}$ 'dan küçük olan partiküller) hava kalitesi değerlendirilmesinde büyük önem taşırlar.  $PM_{10}$  solunabilir boyuttaki partikül maddeleri içerir ve hızlı çökme özelliğine sahiptir.  $PM_{2,5}$  ise ince partiküller olarak adlandırılırlar ve



havada asılı kalarak uzun mesafeler taşınabilirler [14]. İnsan saçı ile *PM* boyut sınıflandırması Şekil 2.2'de verilmiştir.

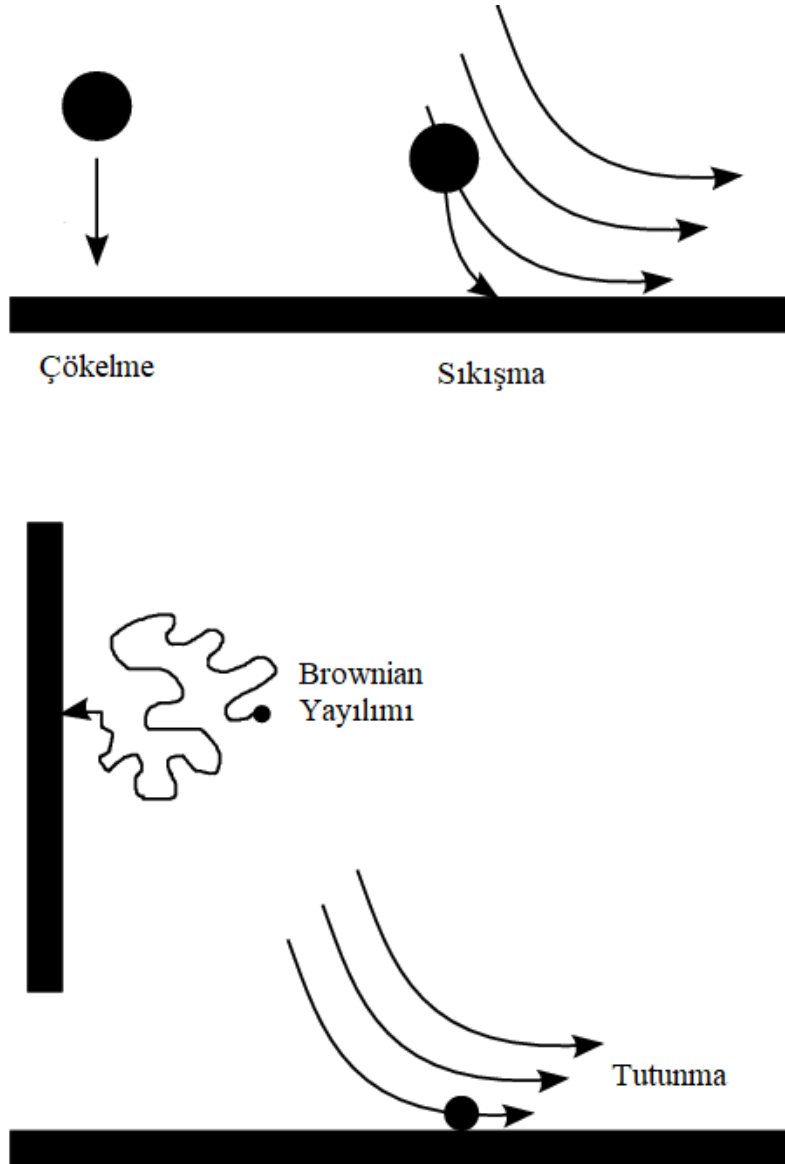


Şekil 2.2: Partikül madde boyut dağılımı gösterimi [14]

#### 2.2.4.2 Partikül Mekanikleri

Partiküller atmosfere salındıklarında havada doğal yollarla veya insan müdahalesiyle çökmeden önce hava belli bir süre kalırlar ve bazı temel mekanizmalar vasıtasıyla yüzeyler üzerinde toplanırlar. Bu mekanizmaların en önemlileri çökme, Brownian yayılımı, sıkışma ve tutunma olarak adlandırılırlar. Şekil 2.3'de bu mekanizmalar şematik olarak gösterilmektedir. Çökme özellikle havada bulunan partiküller üzerine etki eden iki önemli kuvvetle ilişkilidir. Sürüklenme kuvveti havada buluna partikülün hızı, çapı ve hava ortamının viskozitesi ile doğru orantılı olarak değişmektedir. Yerçekimi kuvveti ise partikülün ağırlığı ile doğru orantılıdır. Eğer partikül üzerine etki eden bu iki kuvvet eşit ise partikül havada asılı kalır. Yerçekimi kuvvetinin büyük olduğu durumlarda partikül aşağıya doğru hareket

eder ve çökelme gerçekleşir. Özellikle boyutu büyük olan partiküllerin çökelme özellikleri daha fazladır [16]. Brownian yayılımı havada bulunan çok küçük boyuttaki partiküllerin atmosferdeki hareket ederken gösterdikleri hareketler olarak tanımlanır. Brownian hareketi ile yayılan partiküller çok daha uzak mesafelere taşınabilir ve etraftaki diğer moleküllerle rastlantısal çarpışmalar yaşarlar [16]. Sıkışma özellikle büyük ve momentuma sahip partiküllerin düzgün bir çizgiyi takip ederek önlerine çıkan engellere takılması ile gerçekleşir. Partikülün ağırlığının artması ve partikül - engel arasındaki hız farkı, momentumun artmasına dolayısıyla partikülün daha düzgün bir yol izlemesine sebep olur. Bu mekanizma ile özellikle büyük partiküller önlerine çıkan herhangi bir engelin yüzeyine sıkışarak birlikte hareket ederler [20]. Tutunma mekanizmasında ise çok küçük boyutlardaki partiküller (0,1-1  $\mu\text{m}$  çaplı) hava sirkülasyonunun etkisi ile önlerine çıkan bir engele değerler ve hava akımından ayrılacak kuvvete sahip olmadıklarından birlikte hareket ederler [20].



Şekil 2.3: Partikül toplama mekanizmaları [21]

### 2.2.4.3 Partikül Kaynakları

Partikül kirleticiler birçok doğal ve insan kaynaklı faaliyetler sonucunda diğer kirleticilerle birlikte veya ayrı olarak atmosfere salınırlar. Özellikle rüzgâr erozyonu ve deniz tuzları atmosferdeki partikül kirliliğinin başlıca doğal kaynaklarıdır. Rüzgâr erozyonu çok ciddi rüzgâr etkisinin olduğu hava koşullarında oldukça etkilidir. Çok kısa sürelerde rüzgâr vasıtasıyla ciddi konsantrasyonlarda partikülün herhangi bir

toplanma olmadan uzak mesafelere taşınımı mümkün olmaktadır. Özellikle boyutları 10  $\mu\text{m}$ 'dan küçük olan partiküller rüzgâr erozyonundan çok daha fazla etkilenirler. Bir diğer etkili doğal partikül kaynağı denizlerdeki dalga hareketleri ile partiküllerin havaya karışması ile oluşurlar. Çoğu havada asılı kalabilecek kadar küçük boyutlardadırlar. Bunun yanı sıra doğal yollarla bazı gaz hava kirleticilerinin partikül formuna geçmesi de partikül kirliliğine katkı sağlamaktadır. Örneğin  $SO_2$  den sülfürik asit aerosolları meydana gelir [16].

Partikül maddeler aynı zamanda antropojenik kaynaklardan da havaya salınırlar. Yanma, erime, öğütme, ezme, sürtme veya püskürtme gibi işlemler partiküllerin havaya salınmasına katkı sağlarlar. Bu yollarla havaya salınan partiküllerin büyük çoğunluğu boyut dağılımlarına göre havada uzun süre askıda kalabilecek kadar küçüktür. Örneğin, dizel kullanılan bir otomobilin bir litrelik yakıt yakması sonucu atmosfere 5 ile 12 g arasında partikül salınımı olmaktadır [16]. Bunun yanı sıra  $NO_2$  nitrat aerosollerinin ana kaynağıdır ve atmosferdeki  $PM_{2,5}$  konsantrasyonuna katkı sağlar. Özellikle motorlu taşıtlar azot oksit ( $NO$ ,  $NO_2$ ,  $NO_x$ ) kirliliğinin başlıca kaynağıdır [22].

#### 2.2.4.4 Partiküllerin Etkileri

Atmosferde bulunan partiküllerden özellikle  $PM_{10}$  ve  $PM_{2,5}$  insan sağlığına ciddi zararlar verebilen kirleticiler arasındadır. Özellikle akciğerlerin derin noktalarına kadar soluma yoluyla gidebilirler ve sağlık açısından ciddi zararlı etkileri vardır.  $PM_{10}$  kirleticileri üst solunum yollarında filtre edilebilirken,  $PM_{2,5}$ 'un bronşlara kadar girebilmektedir ve tehlikesi çok daha fazladır.  $PM_{2,5}$  akciğerlerin içerisinden kana karışabilme yetisine bile sahiptir.  $PM$  kaynaklı hava kirliliği solunum yolu rahatsızlıkları, nefes almada zorluk, öksürük, akciğer fonksiyonlarında azalma, kalp krizi, astım krizi, prematüre doğum gibi birçok hastalığa sebebiyet verebilir ve bu sebeplerden kaynaklı ölüm vakaları olduğu tespit edilmiştir [8]. Özellikle yaşlılar, çocuklar, halihazırda akciğer ve kalp sorunu olan kişilerde  $PM$ 'in etkileri daha şiddetli gözlemlenebilir [23]. Partikül ölçümleri genellikle dış ortamda yapılmakta ve sağlık etkileri bu ölçümler üzerinde değerlendirilmektedir.

Bu etkilerin yanı sıra partikül maddeler çevreye de ciddi zararlar vermektedir. Özellikle yüksek konsantrasyonlardaki  $PM_{2,5}$ 'un görüşü azaltarak havada sis görüntüsüne sebebiyet verdiği bilinmektedir. Partiküller uzun mesafeler boyunca rüzgarla taşınarak, yer veya su ortamları üzerinde toplanırlar. Kimyasal bileşimlerine bağlı olarak bu partiküller göller ve akarsuları asidik hale getirme, kıyı sularında ve büyük nehir havzalarındaki besin dengesini değiştirme, topraktaki besin maddelerini tüketme, hassas ormanlara ve çiftlik bitkilerine zarar verme, ekosistemlerin çeşitliliğini etkileme ve asit yağmuru etkilerine katkıda bulunur. Bu-

nun yanı sıra PM, heykel ve anıtlar gibi kültürel açıdan önem taşıyan nesnelere de dahil olmak üzere taş ve diğer malzemeleri lekeleyebilir ve zarar verebilir. Malzemeler üzerine olan etkiler daha çok asit yağmurlarıyla ilişkilidir [23].

Partiküllerin ortaya çıkarabileceği sağlık ve çevre etkilerinden kaynaklı olarak dünyada ve Avrupa'da PM konsantrasyonlarının sınırlandırılması ile ilgili yönetmelikler yayımlanmış ve bazı sınır değerler belirlenmiştir. Avrupa Parlamentosu'nun 2008 yılında hazırladığı 2008/50/EU numaralı direktife göre günlük ve yıllık ortalama  $PM_{10}$  sınır değerleri sırasıyla;  $50 \mu\text{g}/\text{m}^3$  ve  $40 \mu\text{g}/\text{m}^3$ , yıllık ortalama  $PM_{2,5}$  sınır değeri ise  $25 \mu\text{g}/\text{m}^3$  olarak belirlenmiştir [24]. WHO (Dünya Sağlık Örgütü) ise özellikle kirliliğin olumsuz sağlık etkilerinin azaltılabilmesi için günlük ve yıllık ortalama  $PM_{2,5}$  sınır değerlerinin sırasıyla;  $25 \mu\text{g}/\text{m}^3$  ve  $10 \mu\text{g}/\text{m}^3$  olması gerektiğini önermiştir. [25] Türkiye'de 03.07.2009 tarih ve 27277 sayılı Sanayi Kaynaklı Hava Kirliliğinin Kontrolü Yönetmeliği'nde,  $PM_{10}$  standartları günlük ve yıllık ortalama olarak sırasıyla;  $50 \mu\text{g}/\text{m}^3$  ve  $40 \mu\text{g}/\text{m}^3$  olarak belirlenmiştir [26]. Türkiye'de yayımlanan yönetmeliklerde  $PM_{2,5}$  ile ilgili bir standart bulunmamaktadır.

## 3 Yapay Zeka

Yapay zeka, çevresel konular dahil birçok farklı alan için en çok kullanılan modelleme yaklaşımlarından biridir. Yapay zeka insan beyni gibi çalışmak için programlanır ve bu özellikleri kullanır [27]. Örneğin, insan beyninin paralel yaklaşım, hesaplama, öğrenme yeteneği, genelleme yeteneği ve uyarlayabilme yeteneği gibi birçok özelliğini kullanır. Yapay zeka ile insanların temel eğilimleri, algı ve öğrenme yetileri ve davranışları makineler tarafından da aynı insanların yaptığı kadar iyi çözümlenebilir [28, 29]. Yapay zeka, amacı doğrultusunda iki ana çerçevede tanımlanabilir. Mühendislikte yapay zeka dünyada yer alan gerçek günlük sorunlara makinalar aracılığıyla çözüm bulmaya çalışır. Bilimsel olarak ise yapay zeka bilgiyi temsil eder ve bilgiyi sistemler ile entegre ederek makina zekasını ortaya çıkarır [30].

Yapay zeka bilgisayar biliminin alt dalıdır [31]. Yapay zeka 1950'lerde beynin çalışma mantığının sorgulanması ile başlamış bir akımdır. O zamanlar, bilgisayarları insan beyni gibi çalıştırılabilmek amaçlanmış ve bilgisayarlara akıl yürütmeyi öğretmek denenerek devrim niteliğinde bir buluşa imza atılmıştır. Bilgisayarlar hayatımıza girmeden önce canlılar arasında en üstün zeka örneği olarak sadece insanın zekâsı bilinmekteydi. Şimdilerde ise akıllı bilgisayarlar hayatımızda yer almaktadır. Yapay zeka sayesinde insanlar tarafından oluşturulan makinalar, akıl yetisine sahip canlıların davranışlarını taklit ederek otomatik bir şekilde yapabilir [32]. Yapay zeka çeşitli alanlarda karmaşık problemleri çözmek için kullanılmaktadır ve bu alanlarda kalite ve verimlilikte bir artış görülmüştür [31, 33].

Yapay zeka sistemleri, bilginin eğer - veya (IF-ELSE) gibi kurallar oluşturarak bilgisayara tanımlanması ile oluşur. Bu yöntemde problemler, yüklenen bilgide değişiklik yapan çıkarım mekanizması ile çözülür. Bu yöntemin uygulamaları, sinyal yorumlama, arıza teşhisi, makine tasarımı, malzeme seçimi ve makine ve proses kontrolü gibi geniş kapsamlarda kullanılmaktadır [12, 29]. Yapay zeka ile oluşturulan mantıksal yazılımların otomasyon sistemleri, bilgisayarın karar verme gücünden faydalanarak ihtiyaca yönelik gerek bireysel gerekse ticari sistemler ortaya çıkarmakta ve sistemlerin fonksiyonel özellikleri artmaktadır [34].

## 3.1 Makine Öğrenmesi

Makine öğrenmesi, bir veri içindeki örüntüleri otomatik olarak tespitte etme ve bu örüntülerin gelecek verilerini tahmin etme amaçlı veya belirsiz bir konuda karar verme mekanizması oluşturma amaçlı kullanan yöntemlerin tamamı olarak tanımlanır [35]. Makine öğrenmesi 1980'lerde ortaya çıkmış ve günümüz teknolojisinin temel taşlarından biri haline gelmiştir. Makine öğrenmesi, tahmin, sınıflandırma, kümeleme gibi karmaşık modelleri ve algoritmaları tasarlamak için kullanılan bir yöntemdir [27, 36]. Bu teknolojiler günlük hayatta insanlara faydalı ürünlerin oluşmasına katkıda bulunmaktadır. Makine öğrenmesi başlıca üç ana sınıftan oluşmaktadır. Bunlar öğreticiyle öğrenme, gözetimsiz öğrenme ve takviyeli öğrenme olarak adlandırılır. Öğreticiyle öğrenmede makineye doğru çıktı verileri verilerek giriş ve çıkış verileri arasında bir bağlantı kurulması sağlanır. Öğreticiyle öğrenmede problemler regresyon ve sınıflandırma ile çözülür. Gözetimsiz öğrenmede ise öğreticiyle öğrenmenin tam tersi bir mekanizma işlemektedir. Bu yöntemde çıktı verileri makineye verilmeyerek, sonuç verisinin makine tarafından sadece giriş verileri yardımıyla kümelenebilmesi sağlanır. Takviyeli öğrenmede makinenin içerisinde, sonucu öğretici tarafından bilinen veri ortamına sokularak, deneme yanılma yoluyla öğrenmesi sağlanmaktadır. Makine geçmiş deneyimleri öğrenerek probleme en uygun çözümü bulmaya çalışır [37, 38].

Makine öğrenmesi, alt sınıfları içerisinde kolay kullanılması ve doğruluğunun daha kolay hesaplanabilmesi nedeniyle en çok kullanılan öğrenme türü öğreticiyle öğrenmedir. Öğreticiyle öğrenmede kullanılan birçok algoritma vardır. Bu algoritmalarından bazıları lineer regresyon, lojistik regresyon, saf Bayes, karar ağacı, sinir ağlarıdır. Sinir ağları (çok katmanlı algılayıcı) özellikle hava kirliliği modellenmesinde en çok kullanılan algoritmalarındandır. Yapay sinir ağlarının ana özelliği biyolojik sinir ağlarının çalışma mantığından ilham almasıdır [39]. Bir sinir ağında birçok farklı makine öğrenme algoritması birlikte çalışarak kompleks giriş verilerini çözümlenmeye çalışır. Yapay sinir ağları birbirine bağlı noktalardan oluşur ve bu noktalara yapay nöron ismi verilir. Bu ağda bulunan her bağlantı aynı biyolojik sistemlerdeki sinapslar gibi sinyalleri bir nörondan diğerine aktarır. Sinyali alan nöron bunu işleyerek bunu bağlı bulunduğu başka bir nörona aktararak işlem yapar [40]. Yapay sinir ağlarının bazılarında öğrenme işlemi geri beslemeli öğrenme algoritması ile sağlanır. Bu öğrenme sistemi önceki katmanlardaki hatalara bakarak ve her bir noktayı ağırlıklandırarak hatayı en aza indirmeye çalışır. Geri beslemeli sistemlerde özellikle gradyanın yok olması sorunuyla karşılaşılabilir. Gradyanın yok olması durumunda yapay sinir ağlarındaki öğretim işleminde sorunlar yaşanmaya başlanır ve öğretim tamamen durabilir. Bu sorunun ana kaynağı öğretim işleminde iterasyonlar sırasında belirlenen ağırlıklara göre alınan hata fonksiyonunun kısmi in-

tegralinin ağırlık değeri olarak sinir ağına eklenmesidir. Özellikle gradyanın çok küçük olduğu durumlarda sinir ağı ağırlıkların değişmesine izin vermemekte ve öğretmenin kısmi olarak ya da tamamen durmasına sebep olmaktadır. Bu problemin aşılması amacıyla derin öğrenme metotları geliştirilmiştir [41].

### 3.1.1 Derin Öğrenme

Derin Öğrenme, beynin yapay sinir ağları olarak adlandırılan yapısı ve işlevinden esinlenen algoritmalarla ilgili bir makine öğrenim alt-alanıdır [27]. Özellik çıkarma ve dönüştürme için birçok doğrusal olmayan işlem birimi katmanları kullanılır. Bu katmanlar birbirini takip eder [36]. Her ardışık katman, önceki katmandaki çıktıyı girdi olarak alır [11]. Algoritmalar denetimli (sınıflandırma gibi) veya denetimsiz (desen analizi gibi) olabilir. Sonunda, yüksek doğrulukla rekabet yaratırlar. Ayrıca, çevresel problemler göz önünde bulundurulduğunda, derin öğrenmenin kirlilik kaynaklarının yerini bulma, kirlilik seviyelerinin yüksek olduğu alanları tespit etme ve gelecekteki konsantrasyonları tahmin etme yeteneği vardır.

Derin öğrenme aşağıda belirtilen adımları kullanılarak çalışır: 1) İlgili veri kümelerini tanımlanır ve analiz için hazırlanır, 2) kullanılacak algoritmanın türü seçilir, 3) kullanılan algoritmaya dayalı bir analitik model oluşturulur, 4) test veri setlerindeki model eğitilir, gerektiğinde revize edilir, 5) test puanlarını oluşturmak için model çalıştırılır ve 6) sonuca göre ileriye yönelik tahmin oluşturulur.

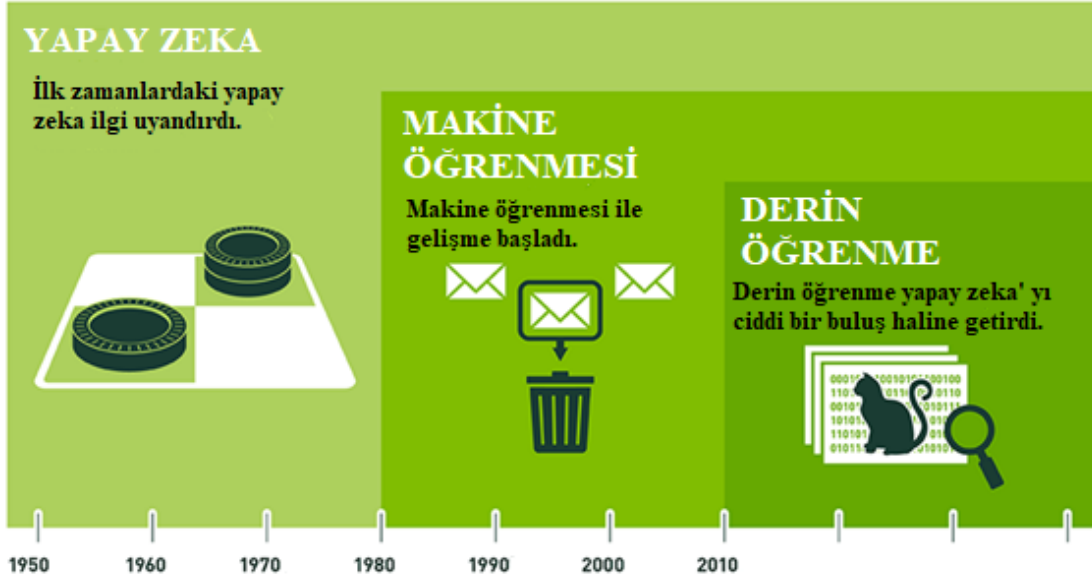
Makine öğrenimi ve derin öğrenme arasındaki temel farklılıklar iki maddeyle açıklanabilir. Birincisi veri büyüklüğü ve ikincisi problem çözme yöntemleri. Derin öğrenmede, makine öğrenmesi ile karşılaştırıldığında daha büyük veri kullanılır. Derin öğrenme, uçtan uca problem çözme üzerine odaklanırken, makine öğrenimi kullanımı, problem yöntemini bölüştürmekte ve yönetmektedir. Dahası, derin öğrenme, sıralı katmanlarda aynı işlemi gerçekleştirirken, makine öğrenimi genellikle tek bir katman halinde işlem yapar.

Derin öğrenme modellerinin çoğu, giriş ve çıkış vektörü belirleme, transfer fonksiyonu belirleme, ağ yapısı seçimi, gizli katman belirleme sayısı, ağırlık özellikleri ve öğrenme algoritması seçimi gibi çeşitli adımları izleyerek geliştirilmiştir. Derin öğrenme modelinin genel yapısı girdi, gizli ve çıktı katmanlarından oluşur. Bu katmanların her biri sayısal bir değer ile ağırlıklandırılmalıdır [42]. Gizli katmandaki nöronlar, giriş ve çıkış nöronlarından, öğrenme algoritmasından, ağ yapısından ve aktivasyon fonksiyonunun türünden etkilenir [10,11]. Gizli katmandaki nöronların sayısını belirlemek için, farklı ağları eğitmek ve test verisindeki hatayı araştırmak gerekir [11].



### 3.1.1.1 Derin Öğrenmenin Tarihçesi

Derin öğrenme yakın geçmişin konusu gibi gözükmese de temelleri yapay zekâ ile birlikte 1940’larda atılmıştır. İlk matematiksel sinir ağı 1943 yılında nöroloji uzmanı Walter Pitts tarafından geliştirilmiştir. Bu büyük atılımdan sonra 1950 yılında bir İngiliz matematikçi olan Alan Turing makine öğrenmesinin mümkün olabileceğini söylemiştir. 1952 yılında Arthur Samuel ilk makine öğrenme programını geliştirmiş ve bilgisayarla dama oynamak için bu programı kullanarak bilgisayarın öğrenme özelliğini kullanmıştır. 1959 yılına gelindiğinde David H. Hubel ve Torsten Wiesel basit ve kompleks hücre yapılarını keşfederek yapay sinir ağlarının gelişimine katkıda bulunmuşlardır. 1960 senesinde Henry J. Kelley uçakların izleyebileceği muhtemel yollarla ilgili bir kontrol teorisi geliştirmiş ve bu sayede geri beslemeli öğrenme algoritmasının temelleri atılmıştır. 1965 senesinde Alexey Ivakhnenko ilk bilgisayar tabanlı çok parametrelili veri setlerini matematiksel olarak modellemiş ve sinir ağlarına uygulamıştır. Bu çalışma ile günümüzde kullanılan modern derin öğrenmenin temeli atılmıştır. 1979-80 yıllarında Kunihiko Fukushima yapay sinir ağlarına görsel verileri algılamayı öğretmiştir. 1982 senesinde ise devirli sinir ağlarının temeli olan Hopfield ağlarını ortaya çıkarmıştır. 1985 ve 86 senelerinde programlara İngilizce kelimeleri telaffuz etme ve şekilleri tanıyarak kelimeleri tahmin etme öğretilmiştir. 1989 senesinde makineler el yazısı haneleri okumaya başlamışlardır. 1993 senesinde Jürgen Schmidhuber derin öğrenme için önemli bir gelişmeye imza atarak çok derin öğrenme görevini çözümlenmiş yaklaşık 1000 katmandan oluşan devirli sinir ağı kullanmıştır. 1997 senesinde uzun-kısa dönem hafıza (LSTM) modeli ilk kez ortaya atılmıştır. 1998 senesinde gradyan temelli öğrenme geliştirilmiş ve geri yayımlı öğrenme ile birleştirilmiştir. 2009 ve 2011 senelerinde resim algılama ve kıvrımlı sinir ağları kullanılarak derin öğrenme bir üst seviyeye taşınmıştır. 2014 senesinde ise yüz algılama sistemi geliştirilmiştir. Günümüzde derin öğrenme her alanda karşımıza çıkarak hayatlarımızda yer almaya devam etmektedir [43]. Derin öğrenme her geçen gün verilerin dünyasında daha fazla söz sahibi olmaktadır. Şekil 3.1’de, yıllara göre yapay zekâ, makine öğrenmesi ve derin öğrenmenin gelişim basamakları verilmiştir.



Şekil 3.1: Yıllara göre yapay zekâ, makine öğrenmesi ve derin öğrenmenin gelişimi [27]

### 3.1.1.2 Derin Öğrenmenin Mühendislik Alanlarında Kullanımı

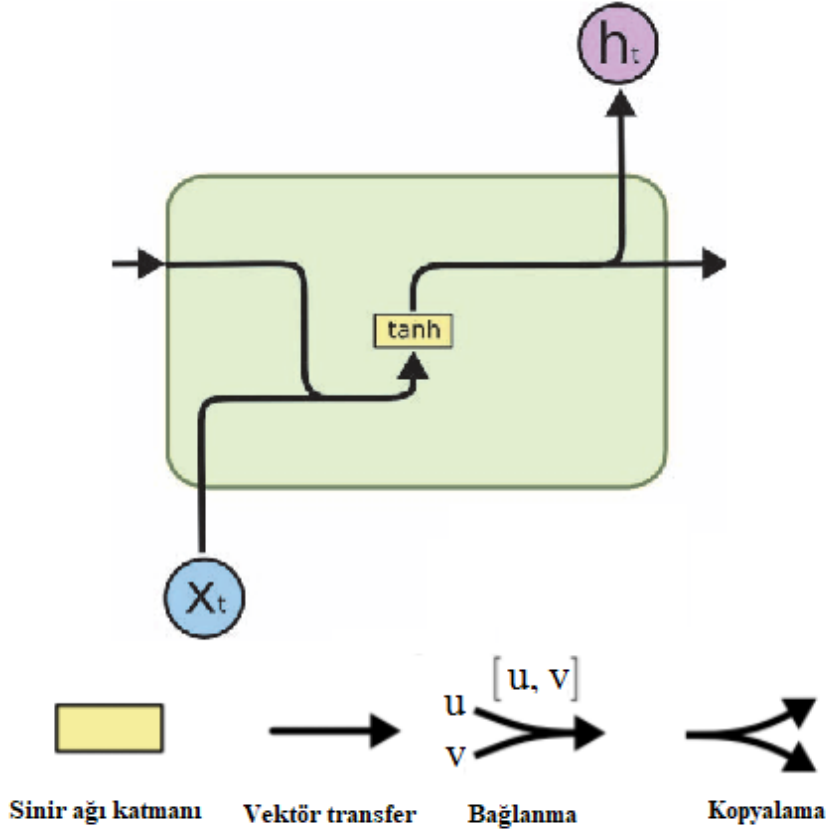
Derin öğrenme sayısal mekanik, dünya bilimleri, sayısal fizik, yaşam bilimleri ve sayısal kimya gibi birçok mühendislik alanında kullanılabilir. Özellikle sayısal mekanik alanında bilgisayar destekli akışkanlar mekaniği üzerine derin öğrenme tabanlı birçok sistem geliştirilmiştir. Bu çalışmaların ana amacı akışkanların mekanik davranışlarını simülasyonlarla modellemektir. Bunun yanı sıra katıların mekaniği de benzer şekilde derin öğrenme ile simüle edilmektedir. Dünya bilimleri daha geniş kapsamlı bir alanı içermektedir. İklim, hava ve okyanus modelleri bu alana girmektedir. Sayısal fizik alanında yer alan birçok problem için derin öğrenme ile model geliştirilmesi mümkündür. Benzer şekilde sayısal kimya alanlarından olan kuantum kimyası ve molekül dinamiği gibi konularda özellikle çözülmesi çok zor olan ve analitik olarak çözülemeyen problemlerin modellenmesi için kullanılmaktadır. Yaşam bilimleri alanında geleneksel yöntemlerle çözülmesi zor uygulamalarda derin öğrenmeden destek alınmaktadır. Gen dizilimleri, hücre yapısı ve protein yapısı alanlarındaki tahminler derin öğrenme ile yapılmaktadır [44].

### 3.1.1.3 Derin Öğrenme ile Hava Kalitesi Modellemesi

Hava kirliliği insan sağlığı ve yaşamının kalitesini belirleyen ana etkenlerden bir tanesidir. Hava'nın farklı kirleticilerle kirlenmesi sonucu insan sağlığı da doğrudan bu

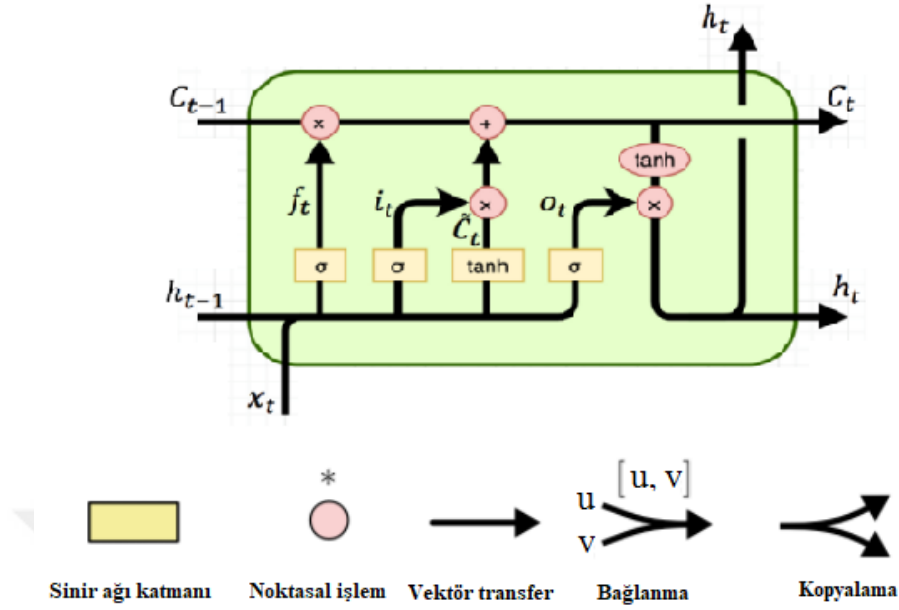
kirlilikten etkilenmektedir. *PM* hem organik hem de inorganik yapıda kirleticileri içinde tutma özelliğine sahip olduğundan, hava kirliliğine sebebiyet veren ciddi etmenlerden birini oluşturmaktadır. Bu sebeple gelecek tahmin modellemesiyle konsantrasyonlarının belirlenmesi çok önemlidir. TÜBİTAK tarafından yürütülen Vizyon 2023: Bilim ve Teknoloji Stratejileri Projesi kapsamında hazırlanan hava kirliliği ön raporunda hava kirleticilerinin izlenmesi ve modellenmesinin gerekliliği vurgulanmıştır. Birçok kurum, dünyanın birçok bölgesinde ciddi hava kirliliği olduğuna dikkat çekmektedir. Hava kirleticilerinin tüm yıkıcı etkileri dikkate alındığında, gelecekteki konsantrasyonları belirlemek veya kirletici kaynakları bulmak için hava kirliliği düzeylerini tahmin etmek için geçerli modeller oluşturmak çok önemlidir. Bu modeller, aşırı kirlilik seviyelerini önlemek için hükümetler ve merkezi yetkililer için politika imkanları sağlayabilir. Literatürdeki kirlilik düzeylerini modellemek için birçok girişimde bulunulmasına rağmen, derin öğrenme tekniklerindeki son gelişmelerle daha fazla veri entegrasyonu ile birlikte daha doğru tahmin sonuçları elde etmek ümit vericidir.

Bu amaçla çeşitli modelleme yöntemleri uygulanmaktadır. Yapay sinir ağları, makine öğrenimini temel alan en çok tercih edilen tekniklerden biridir. Derin öğrenme yapay veri ağlarını bir adım ötede, büyük veri setini kullanarak, bölünmeden problemleri çözerek, daha fazla katman kullanarak, aynı anda ardışık katmanlarla işleyerek ve daha güvenilir sonuçlar sağlayarak bir adım öteye taşır. Derin öğrenmenin tüm bu olumlu özellikleri, onu hava kirliliği modellemesi için uygun bir yöntem haline getirmektedir. Bu amaç için kullanılacak birçok modelleme yöntemi vardır.



Şekil 3.2: RNN blok yapısı [45]


Bunlardan bazıları uzun-kısa dönem hafıza (LSTM) modeli, mekânsal-zamansal derin öğrenmeye (STDL) dayalı hava kalitesi tahmin metodu, derin hava öğrenmesi (DAL), geçitli tekrarlayan ünite (GRU) ve konvolüsyonel sinir ağları (CNN) modelleridir. [46–48]. Özellikle LSTM metodu bu amaçla en çok kullanılan yöntemlerden biridir ve devirli sinir ağlarının (RNN) bir parçasıdır. Şekil 3.2’de RNN modellerinin blok yapısı verilmektedir. RNN modellerinde giriş verileri aktiveleme fonksiyonu sokularak çıkış parametreleri elde edilir [45]. RNN genellikle gelecek tahmini için uygun bir çerçeve ve kirlilik ile meteorolojiyle alakalı zaman serisi verilerini kullanır [47]. LSTM modellerinde hafıza blokları standart RNN’in gizli katmanında yer alan nöronların yerine geçer. LSTM’in kullandığı bu blok sisteminde giriş katmanı, unutmama katmanı ve çıkış katmanı bilgi akışını sağlamaktadırlar [46]. LSTM’de kullanılan blok yapısı Şekil 3.3’te verilmektedir. LSTM modellerinin bir diğer önemli özelliği yapay sinir ağlarında karşılaşılan gradyanın yok olması sorununu çözmesidir.



Şekil 3.3: LSTM blok yapısı [45]

LSTM dışında diğer yaygın kullanılan metot mekânsal-zamansal derin öğrenmeye (STDN) dayalı hava kalitesi tahminidir. Yığın otokodlayıcı modelleri, iç hava kalitesi özelliklerini kaldırmak için bir giriş modeli olarak kullanılır. Yığın otokodlayıcının arkasındaki ana fikir, alt katmanda yığılmış olan otomatik kodlayıcı çıkış katmanını ardışık giriş katmanına bağlar [49].

Bunun yanı sıra, özellik seçimi ve yarı-denetimli öğrenmeyi kullanan DAL modellerinde tahmin performansının artırılması için mekansal zamansal veriler kullanılmıştır. DAL, giriş ve çıkış katmanlarında mekansal ve zamansal yarı denetimli öğrenme ve özellik seçimi de içeren etkili bir yaklaşımdır [50].



Şekil 3.4: GRU blok yapısı [45]

GRU, LSTM ağının bir uzantısıdır. Güncelleme ve unutma kapılarından oluşur. Bunlar tamamen ünite içindeki veri akışının dengelenmesini içerir [51]. Veri serisi GRU'ya giriş olarak verilir. GRU, güncelleme geçidi giriş ve unutma kapıları birleştirilerek oluşturulur. Bu işlem gözetleme deliğindeki bağlantıların olmaması durumunda geçmiş aktivasyon, aday aktivasyonu ve çıkış aktivasyonu arasındaki koşulu dengeler. Unutma kapısı ise önceki durumu sıfırlar. GRU genellikle daha az hesaplama gerektirir ve LSTM ağlarından daha basittir [48]. GRU blok yapısı Şekil 3.4'te verilmektedir. GRU özellikle küçük veri setleri için çok daha başarılı sonuçlar vermektedir [52].

CNN modelleri ise fotoğraf kullanılarak hava kalitesi modellenmesi yapmada kullanılmaktadır. Bu model, modelin orjinal ayırt edici kabiliyetini artıran negatif log-log sınıflandırıcısı ve fotoğraf bazlı hava kirliliği tahmini için geliştirilen Rektifiye Linear Birimleri (ReLU) aktivasyon fonksiyonunu içeren iki temel bileşeni içermektedir [53].

### 3.1.1.4 Önceki Çalışmalardan Örnekler

Hava kirleticilerinin gelecek konsantrasyonlarının tahmin edilmesi, geçtiğimiz yıllarda oldukça fazla çalışılan konular arasında yer almaktadır. Genellikle sınırlı sayıda veri kullanılarak yapılan ve yapay sinir ağlarının kullanıldığı çalışmaların tahmin kabiliyetleri istenilen düzeye ulaşmamıştır. Derin öğrenmenin bu çalışmalarla kıyaslandığında en önemli özelliği, yüksek tahmin kabiliyetine sahip ve güvenilirliği yüksek modeller ortaya koyabilmesidir. Açık literatür tarandığında ülkemizde ve dünyada derin öğrenmenin hava kirliliği verilerine uygulanmasıyla alakalı çalışma sayısının oldukça az olduğu görülmektedir. Derin öğrenme kullanılarak yapılan bazı çalışmalar aşağıda sıralanmaktadır.

Derin öğrenme yönteminin hava kirleticilerinin tahmininde kullanımıyla alakalı Kore’de yapılan bir çalışmada farklı istasyonlardan toplanan meteorolojik veriler  $PM_{2,5}$  tahmini yapmak için kullanılmıştır. Uzun ve kısa zaman periyotları için farklı algoritmalar (LSTM) kullanılarak oluşturulan modellerde, uzun zaman periyotları için daha başarılı sonuçlar elde edilmiştir [54].

Bunun yanı sıra, Çin’in Beijing şehri için derin hava öğrenmesi (DAL) yöntemi kullanılarak yapılan çalışmada şehir ızgara yöntemi kullanılarak bölünmüş her bir bölüme farklı istasyonlardan alınan hava kirleticileri ve meteorolojik veriler yerleştirilerek derin öğrenme yöntemiyle modellenmiştir. Enterpolasyon ve özellik analizi de modellere eklenerek yüksek verimlilikte modeller oluşturulmuştur [50].

Kök ve Özdemir’in 2017 yılında yaptıkları çalışmada LSTM kullanılarak Aarhus ve Brasov şehirleri için  $O_3$  ve  $NO_2$  tahmini yapılmıştır. Bu şehirler için yaklaşık 18.000 veriden oluşan bir veri seti kullanılmış ve yüksek verimlilikte sonuçlar elde edilmiştir [46].

Reddy ve arkadaşları tarafından Çin’in Beijing kenti için yapılan çalışmada ise LSTM yöntemi kullanılmış ve  $PM_{2,5}$  tahmini yapılmıştır. 35 farklı istasyondan alınan veriler ön işlemden geçirilerek saatlik bilgiler düzenlenmiş ve modellere bu verilerle oluşturulmuştur. Yağmur, kar, rüzgâr hızı, rüzgar yönü, sıcaklık ve basınç bilgileri giriş parametreleri olarak kullanılmıştır. Veriler dörde ayrılarak eğitim ve test amaçlı kullanılmıştır. Oluşturulan modellemede 5, 10 ve 120 saat sonrası tahmin etmeye çalışılmış ve %70’e yakın verim elde edilmiştir [47].

Li ve arkadaşları ise STDL temelli bir model geliştirerek  $PM_{2,5}$  tahmini yapmışlardır. Bu çalışmada yığın otokodlayıcı kullanılmış ve yüksek verimlilikte sonuçlar elde edilmiştir [49]. Zhang ve arkadaşları tarafından yapılan bir diğer çalışmada ise  $PM_{2,5}$ ,  $PM_{10}$  tahmini CNN kullanılarak yapılmış ve bu modelde hava kirliliği resimleri kullanılarak tahmin yapılmaya çalışılmış, oldukça düşük ortalama hata elde değerlerine ulaşılarak başarılı sonuçlar edilmiştir [53].

Athira ve arkadaşları ise RNN, LSTM, GRU modellerini  $PM_{2,5}$  tahmininde kullanmış ve yaptıkları üç denemede de başarılı sonuçlar elde etmişlerdir. Özellikle LSTM'in bir uzantısı olan GRU ile yaptıkları modellerde daha başarılı sonuçlar elde edilmiştir. Yaptıkları çalışma ile RNN'in bir parçası olarak değerlendirilen yöntemlerin sonuçları kıyaslanmıştır [48].

Yukarıda açıklamaları verilen çalışmalar Tablo 3.1'de özetlenmektedir. Bu tabloya göre özellikle LSTM ve GRU ile yapılan modellerin sonuçlarının umut verici olduğu görülmektedir. Bununla birlikte farklı yöntemler geliştirilerek oluşturulan modellerden biri olan DAL modeli bu çalışmalar içerisinde en verimli sonucu vermiştir. Yöntemin yanı sıra veri setlerinin boyutu, düzenlenmesi ve çok büyük ya da küçük verilerin modelleme işleminden önce elimine edilmesi model verimliliğini arttıracak unsurlardandır. Ayrıca tahmin yapılmak istenen zaman dilimi de model verimliliğini etkilemektedir. Derin öğrenme kullanılarak oluşturulan modellerin çoğunda kısa süreli tahmin performanslarının daha yüksek çıktığı görülmektedir.

Model	Kirletici	Değerlendirme Kriteri ve Performansı	Kaynak
LSTM	$PM_{2,5}$	RMSE 12,41 (8 saat) RMSE 13,54 (24 saat)	[54]
LSTM	$O_3$	RMSE 3,26 MAE 2,81	[46]
LSTM	$NO_2$	RMSE 3,76 MAE 3,11	[46]
LSTM	$PM_{2,5}$	RMSE 44,15 (5 saat) R2 0,689 (5 saat) RMSE 108,14 (120 saat) R2 -0,328 (120 saat)	[47]
STD	$PM_{2,5}$	RMSE 14,96 MAE 9,00 MAPE 21,75%	[49]
DAL	$PM_{2,5}$	RMSE 0,0667 (1-12 saat) RMSE 0,0877 (37-48 saat)	[50]
CNN	$PM_{2,5}$	AE 0,606	[53]
CNN	$PM_{10}$	AE 0,411	[53]
GRU	$PM_{10}$	MAPE 0,4525	[48]


Tablo 3.1: Derin öğrenme kullanılarak geliştirilen hava kalitesi modelleme çalışmaları




## 4 Veri Temini ve Metot

### 4.1 Çalışma Alanı ve İstasyon Yeri

Keçiören İlçe'si, Ankara'nın merkezine yakın ve Ankara'nın kuzey doğu kesiminde yer almaktadır. Keçiören, Ankara'nın ve Türkiye'nin nüfus olarak ikinci büyük ilçesidir.  $189 \text{ km}^2$  yüzölçümü ile Ankara'nın metropol ilçelerinden biridir. İlçenin ortalama yüksekliği 950 m'dir. Adrese dayalı nüfus kayıt sistemi 2016 verilerine göre 903.565 kişi ile Çankaya'dan sonra Ankara'nın ve Türkiye'nin nüfus bakımından en büyük ikinci ilçesi konumundadır. Türkiye'nin de en kalabalık ilçelerinden biridir ve nüfusu pek çok ilden daha fazladır [55, 56], Şekil 4.1'de Ankara ili ve Keçiören ilçe haritası verilmiştir. Bu tez çalışmasında veri temini amacıyla Keçiören ilçesinde yer alan ölçüm istasyonundan faydalanılmıştır (Şekil 4.2). Örnek bir hava kalitesi ölçüm istasyonu Şekil 4.3'de verilmiştir.



Şekil 4.1: Ankara İl ve Keçiören İlçe Haritası [56]



Şekil 4.2: Keçiören hava kalitesi izleme istasyon yeri [57]

Keçiören'in bölge olarak seçilmesinin ana sebebi bölgedeki istasyonda  $PM_{2,5}$  ölçümünün yapılmasıdır. Bunun yanında bölge için toplam veri miktarı doluluk oranı %89'dur. Ayrıca bu bölgedeki nüfus yoğunluğunun fazla olması ve gelir seviyesinin düşük olmasından kaynaklı olarak kömür ve ücretsiz sağlanan doğal yakıtların kullanımının çok fazla olması, bölgede hava kirliliği kaynaklı sağlık sorunlarına daha sık rastlanmasına sebebiyet vermektedir [58]. Bununla birlikte Ankara'daki diğer istasyon verilerindeki standart sapma (STD) değerlerinin çok yüksek olduğu da dikkate alınmış ve en düşük olan istasyonun Keçiören olduğu tespit edilmiştir. (Tablo 4.1) Bu sebeplerden veri temini için bu bölge tercih edilmiştir.

Tip	Keçiören	Kayaş	Sıhhiye	Demetevler	Dikmen
Maximum	81,5	87,94	78,7	71,88	75,36
Avg	9,677	27,553	27,694	28,058	11,992
Num	721	721	695	137	721
STD	15,61	21,472	15,669	12,21	16,361

Tablo 4.1: Ankara'da bulunan hava kalitesi istasyon verilerinin STD değerleri




Şekil 4.3: Örnek hava kalitesi izleme istasyonu [59]

#### 4.1.1 Çalışma Alanın İklimsel Özellikleri

Ankara genellikle kara ikliminin hüküm sürdüğü bir şehirdir. Güneyde İç Anadolu'nun step-bozkır iklimi, kuzeyde ise Karadeniz bölgesinin yumuşak ve yağışlı özelliği görülür. Ankara ili kışları çok soğuk, yazları ise çok sıcaktır. Yıllık ısı değişikliği 40°C ile -24,9°C arasında değişmektedir. Ortalama yağış ilçelerde farklılıklar gösterir. Yağış 300 mm ile 540 mm arasında, havadaki nem oranı ise %40-79 arasında değişir. Gece ve gündüz arasındaki sıcaklık farkı fazladır. Tuz gölüne inildikçe yağış azalır. Ortalama karlı gün sayısı bir ayı geçmez [60].

Keçiören ilçesine bakıldığında ise yıllık ortalama sıcaklığın  $11,3^{\circ}\text{C}$  yağışın ise 404 mm olduğu görülmektedir. (Şekil 4.4) Keçiören'e kış aylarında yaz aylarından çok daha fazla yağış düşmektedir. Ağustos ayı 11 mm yağışla yılın en kurak ayı iken ortalama 54 mm yağışla mayıs ayı yılın en çok yağmur alan ayıdır. Sıcaklık eğrisi incelendiğinde ise  $22,1^{\circ}\text{C}$  sıcaklıkla Temmuz yılın en sıcak ayı iken Ocak ayında ortalama sıcaklık  $-0,1^{\circ}\text{C}$  olup yılın en düşük ortalamasıdır. Yılın en kurak ve en yağışlı ayı arasındaki yağış miktarı 43 mm'dir ve yıl boyunca ortalama sıcaklık  $22,2^{\circ}\text{C}$  dolaylarında değişim göstermektedir. (Şekil 4.4)



Şekil 4.4: Keçiören İlçesi aylara göre sıcaklık ve yağış değişim grafiği [61]

## 4.2 Veri Temini

Veriler Çevre ve Şehircilik Bakanlığının Keçiören Hava Kalitesi İzleme istasyonu Sürekli İzleme Merkezi [57] tarafından paylaşılan istasyon bazlı veri indirme kısmından 16.11.2018 tarihinde saatlik olarak temin edilmiştir. Veriler tarih-saat bilgisi,  $PM_{2,5}$  ( $\mu\text{g}/\text{m}^3$ ) konsantrasyonu,  $NO$  ( $\mu\text{g}/\text{m}^3$ ) konsantrasyonu,  $NO_2$  ( $\mu\text{g}/\text{m}^3$ ) konsantrasyonu, kabin sıcaklığı ( $^{\circ}\text{C}$ ), bağıl nem (%), kabin nemi (%),  $PM_{10}$  ( $\mu\text{g}/\text{m}^3$ ) konsantrasyonu, güneş radyasyon( $\text{W}/\text{m}^2$ ),  $SO_2$  ( $\mu\text{g}/\text{m}^3$ ) konsant-

rasyonu,  $NO_x$  ( $\mu\text{g}/\text{m}^3$ ) konsantrasyonu, hava Sıcaklığı ( $^{\circ}\text{C}$ ), hava basıncı(mbar), rüzgar hızı(m/s),  $O_3$  ( $\mu\text{g}/\text{m}^3$ ) konsantrasyonu, rüzgar yönü (derece), UVB radyasyonu ( $\text{W}/\text{m}^2$ ), UVA radyasyonu ( $\text{W}/\text{m}^2$ ) şeklindedir.

Bu çalışmada meteorolojik faktörler ve önceki saatlerdeki kirlilik değerleri dikkate alınarak gelecek saatlerdeki  $PM_{2,5}$  tahmini kısa vadeli olarak belirlenmiştir. Verilerin temin edildiği istasyondan saatlik veriler alınmış ancak bu verilerde yaklaşık 10 günde bir 1 saatlik kesinti mevcuttur. Bu kesintinin sebebi hava izleme aletinin filtre değişimi olabilir.  $PM_{2,5}$  tahmini yapılması amacıyla 2017 Ocak ve 2018 Kasım ayları dahil olmak üzere tüm ham veriler temin edilmiştir. İstasyondaki verileri xsl uzantılı excell dosyası olarak verilmektedir. Tablo 4.2’de istasyon verilerinin ham hallerinin bir kısmı örnek olarak verilmiştir.

Tarih	31.10.2018	31.10.2018	31.10.2018	31.10.2018	31.10.2018
$PM_{2,5}$ ( $\mu\text{g}/\text{m}^3$ )	72,76	62,09	-	28,65	15,82
$NO$ ( $\mu\text{g}/\text{m}^3$ )	101,29	152,47	243,3	397,94	265,5
$NO_2$ ( $\mu\text{g}/\text{m}^3$ )	75,13	84,23	100,73	124,74	109,17
Kabin Sıcaklığı ( $^{\circ}\text{C}$ )	20,31	20,35	21,54	22,03	21,85
Bağıl Nem (%)	51,22	48,31	45,27	41,4	30,7
Kabin Nemi (%)	12,45	12,45	12,26	12,25	12,26
$PM_{10}$ ( $\mu\text{g}/\text{m}^3$ )	163,61	98,33	68,19	76,53	77,53
Güneş Radyasyon ( $\text{W}/\text{m}^2$ )	1,12	1,07	0,54	0,44	0,46
$SO_2$ ( $\mu\text{g}/\text{m}^3$ )	6,48	7,1	8,95	12,55	8,12
$NO_x$ ( $\mu\text{g}/\text{m}^3$ )	112,15	154,88	230,85	357,76	251,06
Hava Sıcaklığı ( $^{\circ}\text{C}$ )	10,56	11,6	13,09	15,15	17,78
Hava Basıncı (mbar)	1029,75	1028,63	1027,64	1027,67	1027,25
Rüzgâr Hızı (m/s)	1,73	1,9	1,77	1,31	0,54
$O_3$ ( $\mu\text{g}/\text{m}^3$ )	33,78	46,69	10,25	11,3	9,73
Rüzgâr Yönü (Derece)	37,09	32,62	29,2	32,27	44,14
UVB Radyasyonu ( $\text{W}/\text{m}^2$ )	3,23	3,21	2,88	2,81	2,85
UVA Radyasyonu ( $\text{W}/\text{m}^2$ )	2,32	2,25	1,37	1,19	1,23

Tablo 4.2: Keçiören Hava Kalitesi İzleme İstasyonu ham verileri örneği

### 4.3 Veri Setinin Hazırlanması

Verilerin işlenmesi için <https://colab.research.google.com> adresinde yer alan Google’ın yapay zekâ ve derin öğrenme çalışmaları için ücretsiz olarak sunduğu bulut ortamında yer alan uzak sunucu kullanılmıştır. Google firmasının bulut sunucusu olan Google Drive’a, veriler veri izleme merkezinden indirildiği şekilde xsl uzantısı ile Colab ortamına çekilmiştir. Bu çekim işlemi için Panda kütüphanelerinden xsl işleyici kullanılmıştır. Çekilen verilerin ilk satırında şehir ve ilçe bilgisi yer almaktadır. Bu veriye modelde ihtiyaç olmadığı için veri setinden çıkarılmıştır.

Dönüştürülen veri kümesinin 1. satırı yazdırılır. Bu işlemler Kod 6.1'de, çıkan sonuç ise Şekil 4.5'de gösterilmiştir.

```

2018-10-31 23:00:56      PM2.5(µg/m³)  NO(µg/m³)  NO2(µg/m³)  Kabin Sicakligi(°C)  \
                          72.76      101.29      75.13                20.31

2018-10-31 23:00:56      Bagil Nem(%)  Kabin Nemi(%)  PM10(µg/m³)  \
                          51.22                12.45          163.61

2018-10-31 23:00:56      Gunes Radyasyon(W/m²)  SO2(µg/m³)  NOX(µg/m³)  \
                          1.12                6.48          112.15

2018-10-31 23:00:56      Hava Sicakligi(°C)  Hava Basinci(mbar)  Ruzgar Hizi(m/s)  \
                          10.56                1029.75        1.73

2018-10-31 23:00:56      O3(µg/m³)  Ruzgar Yönü(Derece)  UVB Radyasyonu(W/m²)  \
                          33.78                37.09          3.23

2018-10-31 23:00:56      UVA Radyasyonu(W/m²)
                          2.32

```

Şekil 4.5: Verilerin çekilip bulut ortamına atılması

Veriler bulut ortamına çekildikten sonra ham verilerde Türkçe ve tanımlanamayan karakterler olması nedeniyle veriler Kod 6.2'deki şekilde yeniden isimlendirilmiş ve çıktısı Şekil 4.6'da verilmiştir. Tarih ve zaman bilgisi bir arada olacak şekilde indeks olarak kullanılmıştır (Şekil 4.6).

```

Date      pollution      NO      NO2      KabinSicakligi      BagilNem  \
2018-10-31 23:00:56      72.76  101.29  75.13                20.31      51.22

Date      KabinNemi      PM10      GunesRadyasyon      SO2      NOX  \
2018-10-31 23:00:56      12.45  163.61                1.12  6.48  112.15

Date      HavaSicakligi      HavaBasinci      RuzgarHizi      O3  \
2018-10-31 23:00:56      10.56      1029.75                1.73  33.78

Date      RuzgarYonu      UVB      UVA
2018-10-31 23:00:56      37.09  3.23  2.32

```


Şekil 4.6: Verilerin isimlendirilmiş örneği

Verilerdeki standart sapma (STD) durumunu gözlemlemek amacı ile Kod 6.3'de verilen komut ile STD durumuna bakılmıştır ve işlemler sonucunda Tablo 4.1'deki

veriler ile uyumlu olduğu gözlemlenmiştir.  $PM_{2,5}$  verisi için STD değeri 15,61 şeklinde çıkmıştır. Sonrasında alınan veriler içerisinde boş olan verilerin olduğu satırlar silindikten sonra işleme devam edilmiştir. Kod 6.4 bu amaçla kullanılmıştır.

Veri seti düzenledikten sonra, her bir dizinin hızlı bir taslağı oluşturularak, veriler daha kolay incelenebilir. Ayrıca verilerdeki standart sapma (STD) durumunu gözlemek amacı ile Kod 6.3'te verilen komut ile STD durumuna tekrar bakılmıştır ve  $PM_{2,5}$  verisi için STD değeri 16,25 çıkmıştır.

Ham veriler işlendikten sonra Kod 6.5 kullanılarak verilerin son hali Şekil 4.7'de hava kirliliği zaman serilerinin çizgileri olarak gösterilmiştir.



Şekil 4.7: Hava kirliliği zaman serisi grafikleri

## 4.4 Veri Normalleştirilmesi

Veri düzenlenmesi için ilk işlem veri setini denetlenen bir öğrenme problemi olarak çerçevelendirmeyi ve girdi değişkenlerini normalleştirmeyi içerir. Bir önceki zaman diliminde verilen kirlilik ve meteorolojik veriler kullanılarak şu anki zaman için kirlilik tahmini yapılması mümkündür. Bu tarz bir modelleme için kullanılabilecek alternatifler, hava koşullarına ve son 12 saatteki kirliliğe bağlı olarak bir sonraki saat için kirliliğin tahmin edilmesi veya bir saat için kirliliği tahmin edilip ve bir sonraki saat için beklenen hava koşullarının verilmesidir.

Bu tez çalışmasında hava koşullarına ve son 12 saatteki kirliliğe bağlı olarak sonraki birkaç saat için kirlilik tahmini yapılması planlanmaktadır.

Bu çalışmada kullanılan veri setinin tüm özellikleri öncelikle fit fonksiyonuna sokulur. Verilerde uyumsuzluk olmaması amacı ile bütün veriler int64 şeklinde çevrilir. Sonrasında ise asgari – azami normalleştirilmesi ile normalleştirilir, ardından veri kümesi denetimli bir öğrenme problemine dönüştürülür. Kod 6.6 çalıştırıldığında, dönüştürülen veri kümesinin ilk satırı yazdırılır (Şekil 4.8). Sistemde 17 giriş değişkeni (giriş serisi) ve 1 çıkış değişkeni (mevcut saatteki kirlilik konsantrasyonu) bulunmaktadır.

```
(11990, 255)
  var1(t-12)  var2(t-12)  var3(t-12)  var4(t-12)  var5(t-12)  var6(t-12)  \
12  0.309013   0.144699   0.317181         0.0     0.458333   0.0

  var7(t-12)  var8(t-12)  var9(t-12)  var10(t-12)  ...   var8(t+2)  \
12  0.032705         0.5     0.012121   0.187817   ...         0.5

  var9(t+2)  var10(t+2)  var11(t+2)  var12(t+2)  var13(t+2)  var14(t+2)  \
12  0.006061   0.059222   0.363636   0.852459   0.111111   0.115894

  var15(t+2)  var16(t+2)  var17(t+2)
12  0.125         0.75     0.333333

[1 rows x 255 columns]
```

Şekil 4.8: Normalize edilmiş verilerin örnek satır görüntüsü

## 4.5 Modelin Belirlenmesi ve Uygulanması

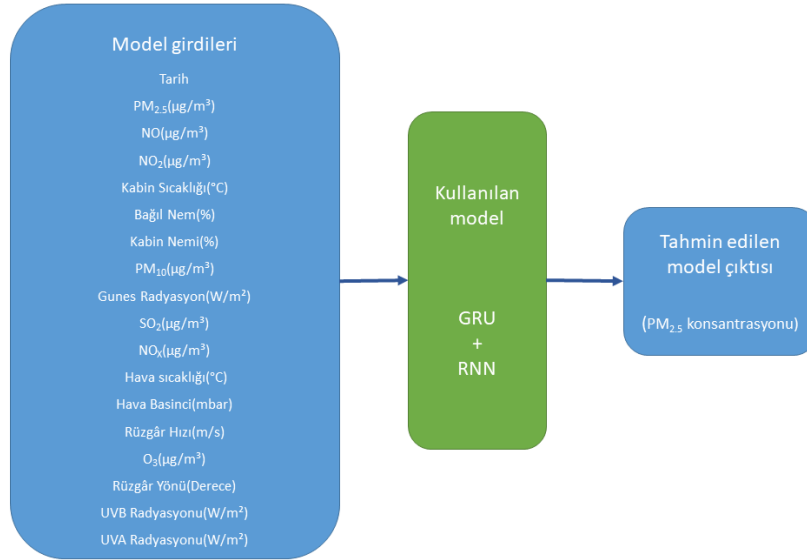
Verilere uygun modeli belirlemek için LSTM, RNN ve GRU modelleri ile farklı kombinasyonlar oluşturulmuş ve 1 saat sonraki hata ve  $R^2$  değerlerine bakılarak hangi modelin daha uygun olduğu belirlenmiştir. Modellerde kullanılacak hafıza bloğu sayısına karar vermek için 10, 50 ve 128’li bloklar kullanılarak denemeler yapılmış, 50 blok kullanılan denemelerde en iyi model performansları elde edilmiştir. Tablo 4.3’de bu modellerin 50 hafıza bloğu kullanılarak yapılan model sonuçlarının karşılaştırması verilmektedir. Model karşılaştırması  $R^2$ , EVS, RMSLE, RMSE, MAE ve STD üzerinden yapılmıştır. Denenen modellerden hata değeri en düşük ve  $R^2$  değeri 1’e en yakın olan kombinasyonun iki katmanlı GRU+RNN olduğu belirlenmiştir.



Model	Değerlendirme Kriteri ve Performansı					
GRU	$R^2 = 0.817$	EVS = 0.793	RMSLE = 0.414	RMSE = 6.897	MAE= 4.492	STD = 5.233
RNN	$R^2 = 0.827$	EVS = 0.790	RMSLE = 0.410	RMSE = 7.138	MAE= 4.703	STD = 5.370
LSTM	$R^2 = 0.801$	EVS = 0.754	RMSLE = 0.429	RMSE = 7.507	MAE= 4.664	STD = 5.882
LSTM+LSTM	$R^2 = 0.815$	EVS = 0.790	RMSLE = 0.430	RMSE = 6.968	MAE= 4.630	STD = 5.207
RNN+RNN	$R^2 = 0.826$	EVS = 0.789	RMSLE = 0.408	RMSE = 7.203	MAE= 4.697	STD = 5.461
GRU+GRU	$R^2 = 0.820$	EVS = 0.811	RMSLE = 0.405	RMSE = 6.573	MAE= 4.354	STD = 4.923
<b>GRU+RNN</b>	<b><math>R^2 = 0.832</math></b>	<b>EVS = 0.828</b>	<b>RMSLE = 0.398</b>	<b>RMSE = 6.282</b>	<b>MAE= 4.211</b>	<b>STD = 4.661</b>
LSTM+RNN	$R^2 = 0.825$	EVS = 0.821	RMSLE = 0.414	RMSE = 6.392	MAE= 4.297	STD = 4.732
LSTM+GRU	$R^2 = 0.816$	EVS = 0.789	RMSLE = 0.439	RMSE = 6.933	MAE= 4.604	STD = 5.184
GRU+LSTM	$R^2 = 0.813$	EVS = 0.765	RMSLE = 0.428	RMSE = 7.373	MAE= 4.799	STD = 5.598
RNN+LSTM	$R^2 = 0.802$	EVS = 0.766	RMSLE = 0.528	RMSE = 7.885	MAE= 5.765	STD = 5.379
RNN+GRU	$R^2 = 0.823$	EVS = 0.821	RMSLE = 0.480	RMSE = 6.859	MAE= 4.853	STD = 4.848

Tablo 4.3: Uygulanan modellerin karşılaştırması

Yapılan denemeler sonucunda GRU+RNN bu tez çalışmasında uygulanan model olmuştur. GRU+RNN modeli oluşturulurken ilk olarak, hazırlanan veri seti eğitim ve test setlerine ayrılmıştır. 2017 ve 2018 yılına ait 500 günlük veri içinden 350 gün eğitim için ayrılmış geriye kalan 150 günlük veri ise test ve validasyon amacıyla kullanılmıştır. Bu işlem için Kod 6.7’de gösterilmiştir. Bu kodda veri kümesi eğitim, test ve validasyon olarak ayrılmakta, eğitim ve test setleri giriş ve çıkış değişkenlerine ayrılmaktadır. Çalışmada uygulanan akış şeması Şekil 4.9’da verilmiştir.



Şekil 4.9: Model akış şeması


Bu modeli çalıştırmak için eğitimin şekli ve test giriş-çıkış kümeleri oluşturulmuştur. Bu işlemlerden sonra GRU+RNN modeli tanımlanabilir ve uygulanabilir hale gelmiştir. Kirlilik tahmini için GRU ve RNN katmanları sırayla tanımlanmış, giriş kısmında 16 özellik ve 1 zaman bilgisi olmak üzere 17 girdi bulunmaktadır.

Ortalama mutlak hata (MAE) kayıp fonksiyonu olarak kullanılmış ve stokastik gradyan eğiminin Adam algoritması ise en iyileştirici olarak kullanılmıştır (Kod 6.8). Oluşturulan modelin görüntülenmesi için Kod 6.9 kullanılmış ve Şekil 4.10'da çıktısı görüntülenmiştir.

Layer (type)	Output Shape	Param #
gru_1 (GRU)	(None, 12, 50)	10200
dropout_1 (Dropout)	(None, 12, 50)	0
simple_rnn_1 (SimpleRNN)	(None, 50)	5050
dropout_2 (Dropout)	(None, 50)	0
dense_1 (Dense)	(None, 3)	153
Total params: 15,403		
Trainable params: 15,403		
Non-trainable params: 0		
None		

Şekil 4.10: Modelin yapısı

Son olarak, modelde fit işlevinde doğrulanacak veri argümanını ayarlayarak eğitim sırasında hem eğitim hem de test kaybı takip edilmiştir. Çalışmanın sonunda hem eğitim hem de test kaybı çizilmiştir. (Şekil 4.11) Bu işlemler Kod 6.10'da verilmiştir.




Şekil 4.11: Modelden elde edilen eğitim ve test kayıpları. Şekilde yatay eksen devir dilimini belirtirken, düşey eksen kayıpları göstermektedir.

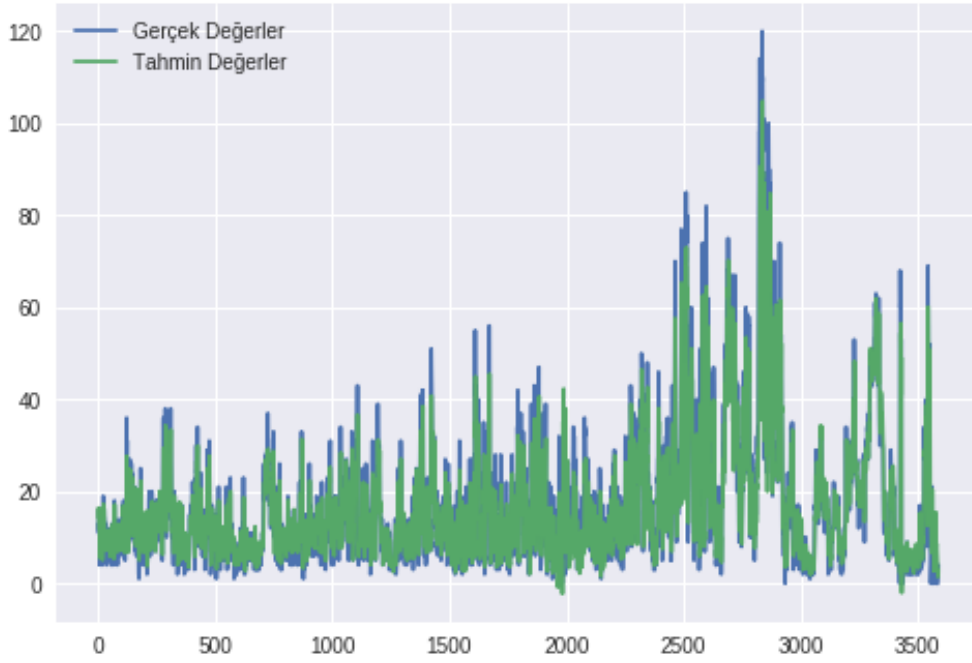
## 4.6 Model Sonuçları

Modelin uygulanması sonucunda, tüm test veri seti tahmin edilebilir. İlk olarak, tahminler test veri seti ile birleştirilerek normalizasyon tersine çevrilmiştir. Ardından tahminler ve gerçek değerler kullanarak model için bir hata puanı hesaplanmıştır. Bu çalışmada, değişkenin kendisi ile aynı birimlerde hata veren regresyon skoru ( $R^2$ ), Açıklanmış varyans regresyon skoru (EVS), kök ortalama karekök logaritmik sapması (RMSLE), kök ortalama karekök sapması (RMSE), ortalama mutlak hata (MAE) ve standart sapma (STD) hesaplatılmıştır. 1 saat, 2 saat ve 3 saat sonraki kirlilik tahminleri için elde edilen hata değerleri ve  $R^2$  değerleri verilmiştir. Kod 6.12'de sonuçların yazdırılması için kullanılan kodlar yer almaktadır.

Bir saat sonraki değerler  $R^2 = 0,832$ ,  $EVS = 0,829$ ,  $RMSLE = 0,404$ ,  $RMSE = 6,272$ ,  $MAE = 4,211$  ve  $STD = 4,649$  şeklindedir. Şekil 4.12'de bir saatlik tahminin regresyon eğrisi, Şekil 4.13'te ise gerçek ve tahmini değerlerin karşılaştırması grafiksel olarak verilmiştir.




Şekil 4.12: Bir saat sonraki hava kirliliği tahminleri için regresyon eğrisi. Şekilde yatay eksen  $\mu\text{g}/\text{m}^3$  tahmini konsantrasyon miktarını belirtirken, düşey eksen  $\mu\text{g}/\text{m}^3$  gerçek konsantrasyon miktarını göstermektedir.




Şekil 4.13: Bir saat sonraki gerçek ve tahmini değerlerin karşılaştırması. Şekilde yatay eksen saatlik zaman dilimini belirtirken, düşey eksen  $\mu\text{g}/\text{m}^3$  konsantrasyon miktarını göstermektedir.

2 saat sonraki değerler  $R^2 = 0,709$ ,  $EVS = 0,700$ ,  $RMSLE = 0,507$ ,  $RMSE = 8,451$ ,  $MAE = 5,696$  ve  $STD = 6,242$  şeklindedir. Şekil 4.14'te 2 saatlik tahminin regresyon eğrisi, Şekil 4.15'de ise gerçek ve tahmini değerlerin karşılaştırması grafiksel olarak verilmiştir.




Şekil 4.14: İki saat sonraki hava kirliliği tahminleri için regresyon eğrisi. Şekilde yatay eksen  $\mu\text{g}/\text{m}^3$  tahmini konsantrasyon miktarını belirtirken, düşey eksen  $\mu\text{g}/\text{m}^3$  gerçek konsantrasyon miktarını göstermektedir.




Şekil 4.15: İki saat sonraki gerçek ve tahmini değerlerin karşılaştırması. Şekilde yatay eksen saatlik zaman dilimini belirtirken, düşey eksen  $\mu\text{g}/\text{m}^3$  konsantrasyon miktarını göstermektedir.

3 saat sonraki değerler  $R^2 = 0,611$ ,  $EVS = 0,606$ ,  $RMSLE = 0,576$ ,  $RMSE = 9,789$ ,  $MAE = 6,554$  ve  $STD = 7,270$  şeklindedir. Şekil 4.16'da 3 saatlik tahminin regresyon eğrisi, Şekil 4.17'de ise gerçek ve tahmini değerlerin karşılaştırması grafiksel olarak verilmiştir.



Şekil 4.16: Üç saat sonraki regresyon eğrisi. Şekilde yatay eksen  $\mu\text{g}/\text{m}^3$  tahmini konsantrasyon miktarını belirtirken, düşey eksen  $\mu\text{g}/\text{m}^3$  gerçek konsantrasyon miktarını göstermektedir.





Şekil 4.17: Üç saat sonraki gerçek ve tahmini değerlerin karşılaştırması. Şekilde yatay eksen saatlik zaman dilimini belirtirken, düşey eksen  $\mu\text{g}/\text{m}^3$  konsantrasyon miktarını göstermektedir.

## 4.7 Sonuçlarının Değerlendirilme Kriterleri

Model sonuçları hata ve  $R^2$  değerlerine bakılarak değerlendirilmiştir.  $R^2$  değeri gerçek değerlere, tahmin değerlerinin birbirleriyle olan uyumunu gösteren regresyon denklemi ile hesaplanır ve 1'e yakın olması değerlerin birbirlerine benzerliğinin yüksek olduğunun bir göstergesidir. Bununla birlikte hata değerleri de modelin performansı değerlendirirken oldukça önemlidir. Hata değerlerinin 0'a yakın olması bu modelin performansının başarılı olduğu hakkında fikir verir.

## 5 Sonular

Derin ğrenme yntemini hava kirletici tahmininde kullanmak son zamanların dikkat eken konuları arasındadır. Bu alıřma ile yksek doėruluga sahip tahminler oluřturarak, belediye ve bakanlıklar vasıtasıyla halkın konu ile ilgili bilinlenmesinin ve gerekli nlemlerin alınmasının saėlanması amalanmıřtır. Bu alıřma sonucunda  $R^2$  deėerleri 1 saatlik tahmin iin 0,832, 2 saatlik tahmin iin 0,709 ve 3 saatlik tahmin iin 0,611 olarak bulunmuřtur. Bu sonular dikkate alındığında oluřturulan GRU+RNN modelinin kısa sreli tahmin performansının yaklařık %83 ıktığı grlmektedir. Tahmin sresi uzadıėında ise verimde biraz dřř yařanmaktadır. GRU ve RNN modelleri kısa sreli tahmin performansı aısından ok daha verimlidir.

Bu alıřma sonucunda elde edilen modellemenin tahmin performansının, bu alanda yapılan nceki alıřmaların sonuları ile karřılařtırıldıėında olduka bařarılı olduėu grlmektedir. Veri sayısının artırılması veya kullanılan yntemde yapılan bazı deėiřiklerle daha iyi sonular almak mmkn olabilir. Bununla birlikte, modelin tahmin performansı verilerin iinde ok fazla eksik deėerin olmasından etkilenmiř olabilir. Eksik deėerler bu alıřmada tm stunun ortalaması alınarak doldurulmuřtur. Bu modelin tahmin performansını etkilemiř ve ğrenmenin yeterince iyi olmamasına sebebiyet vermiř olabilir. Ayrıca verilerin ierisinde bulunan ok yksek veya dřk deėerler de modelin verimliliėini etkilemiř olabilir. Bu alıřmada bu deėerleri elimine etmek iin herhangi bir iřlem uygulanmamıř, standart sapması en dřk olan ile alıřma alanı olarak tercih edilmiřtir. Bunun yanı sıra veri setleri farklı meteorolojik etmenler ve kirlilik konsantrasyonları ile oluřturulmuř, toplamda 17 giriř parametresi modele sokulmuřtur. Bu parametrelerden bazılarının  $PM_{2,5}$  kirliliėine etkisi diėerlerine gre daha az olabilir, bu da model performansını negatif ynde etkilemiř olabilir. Bunun yanı sıra giriř verileri ierisinde yaėmur verisi yer almamaktadır.  $PM_{2,5}$  kirliliėi yaėmurla doėrudan ilgilidir. Yaėmurun ok olduėu zamanlarda havada toz halde bulunan  $PM$  seviyesinde azalma olması muhtemeldir. Bu verinin modele parametre olarak girilememesi de performansı etkilemiř olabilir.

Sonuçları elde etmek için alternatif denemeler de yapılmıştır. Bu çalışmada optimizasyon için Adam algoritması kullanılmış, alternatif olarak softmax, sgd ve sigmoid algoritması denenmiştir. Kayıp fonksiyonu için ise ortalama mutlak hata (MAE) kullanılmış, alternatif olarak ortalama kareli hata (MSE) kullanılmış ve deneme yapılmıştır. Gün sayısı ile de farklı sayılarda denemeler yapılmış fakat sonuçların başarılı çıkmamasından dolayı denemeye devam edilmemiştir.

$PM_{2,5}$  modellemesine odaklanan çok sayıda çalışma olmasına rağmen, derin öğrenme yöntemi kullanılarak yapılan  $PM_{2,5}$  modellemesi nispeten yeni bir konudur. Bu alanda sınırlı sayıda çalışma bulunmaktadır ve ilerleyen süreçte yapılabilecek daha fazla araştırmanın temelini oluşturabilir.

Özellikle solunum yolundan bronşlara kadar girebilen  $PM_{2,5}$  solunum yolu rahatsızlıkları, nefes almada zorluk, öksürük, akciğer fonksiyonlarında azalma, kalp krizi, astım krizine, prematüre doğum gibi birçok hastalığı sebebiyet verebilir. Ayrıca yüksek konsantrasyonlardaki  $PM_{2,5}$ 'in görüşü azaltarak havada sis görüntüsüne sebebiyet verebilir. Kimyasal bileşimlerine bağlı olarak bu partiküller göller ve akarsuları asidik hale getirme, kıyı sularında ve büyük nehir havzalarındaki besin dengesini değiştirme, topraktaki besin maddelerini tüketme, hassas ormanlara ve çiftlik bitkilerine zarar verme, ekosistemlerin çeşitliliğini etkileme ve asit yağmuru etkilerine katkıda bulunur. Tüm bu özellikleri dikkate alındığında  $PM_{2,5}$ 'in gelecek konsantrasyonlarını belirlemek, emisyon kontrol ile ilgili yasa ve yönetmeliklerin hazırlanması, muhtemel kirletici kaynakların belirlenmesi, ani gelişebilecek aşırı kirliliğin kontrolü, önlemlerin alınması ve şu anki kirletici kaynakların gelecekte ortaya çıkabilecek kirlilik olaylarındaki rolünün belirlenmesi açısından oldukça önemlidir. Bu sebeple bu çalışma sayesinde aynı çalışma alanı için daha uzun süreli tahmin performansına sahip modeller geliştirilebilir.

## 6 Ekler

```
1 dataset = pandas.read_excel('https://docs.google.com/uc?id=1475
    ↪ WvpjM58le9P60z6NdKKOrN1Dean7c&export=download', skiprows=[0],
    ↪ index_col=0)
2 print(dataset.head(1))
```

Kod 6.1: Verilerin çekilmesi [62]

```
1 dataset.columns = ['pollution', 'NO', 'NO2', 'KabinSicakligi', 'BagilNem', 'KabinNemi',
    ↪ PM10', 'GunesRadyasyon', 'SO2', 'NOX', 'HavaSicakligi', 'HavaBasinci',
    ↪ RuzgarHizi', 'O3', 'RuzgarYonu', 'UVB', 'UVA']
2 dataset.index.name = 'Date'
3 print(dataset.head(1))
```

Kod 6.2: Verilerin isimlendirilmesi

```
1 print("%.3f" % numpy.std(numpy.absolute(dataset['pollution'])))
```

Kod 6.3: Standart sapma hesabı

```
1 dataset = dataset[numpy.isfinite(dataset['pollution'])]
2 dataset = dataset[numpy.isfinite(dataset['PM10'])]
3 dataset = dataset[numpy.isfinite(dataset['KabinNemi'])]
4 dataset = dataset[numpy.isfinite(dataset['HavaSicakligi'])]
5 dataset = dataset[numpy.isfinite(dataset['KabinSicakligi'])]
6 dataset = dataset[numpy.isfinite(dataset['HavaBasinci'])]
7 dataset = dataset[numpy.isfinite(dataset['GunesRadyasyon'])]
8 dataset = dataset[numpy.isfinite(dataset['NOX'])]
9 dataset = dataset[numpy.isfinite(dataset['NO2'])]
```

```

10 dataset = dataset[numpy.isfinite(dataset['SO2'])]
11 dataset = dataset[numpy.isfinite(dataset['NO'])]
12 dataset = dataset[numpy.isfinite(dataset['RuzgarYonu'])]
13 dataset = dataset[numpy.isfinite(dataset['RuzgarHizi'])]
14 dataset = dataset[numpy.isfinite(dataset['O3'])]
15 dataset = dataset[numpy.isfinite(dataset['UVB'])]

```

Kod 6.4: Boş verilerin veri setinden çıkarılması [62]

```

1 from matplotlib import pyplot
2 values = dataset.values
3 groups = [0, 1, 2, 3, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16]
4 i = 1
5 pyplot.figure(figsize=(20,10))
6 for group in groups:
7     pyplot.subplot(len(groups), 1, i)
8     pyplot.plot(values[:, group])
9     pyplot.title(dataset.columns[group], y=0.9, loc='left')
10    i += 1
11 pyplot.show()

```

Kod 6.5: Zaman serilerinin oluşturulması [62,63]

```

1 values = dataset.values
2 scaler = MinMaxScaler(feature_range=(0, 1))
3 scaled = scaler.fit_transform(values)
4 reframed = series_to_supervised(scaled, n_hours_past, n_hours_future)
5 print(reframed.shape)
6 print(reframed.head(1))

```

Kod 6.6: Normalleştirme ve denetimli öğrenme problemi [64]

```

1 values = reframed.values
2 n_train_hours = 350 * 24
3 train = values[:n_train_hours, :]
4 test = values[n_train_hours:, :]
5
6 n_obs = n_hours_past * n_features
7
8 train_X = train[:, :n_obs]

```

```

9 test_X = test[:, :n_obs]
10 train_X = train_X.reshape((train_X.shape[0], n_hours_past, n_features))
11 test_X = test_X.reshape((test_X.shape[0], n_hours_past, n_features))
12 print(train_X.shape, test_X.shape)

```

Kod 6.7: Verilerin ayrıştırılması

```

1 model = Sequential()
2 model.add(GRU(50, input_shape=(train_X.shape[1], train_X.shape[2]), activation='
↪ tanh', return_sequences=True))
3 model.add(Dropout(0.15)) # Dropout overfitting
4 model.add(SimpleRNN(50, activation='tanh', return_sequences=False))
5 model.add(Dropout(0.15)) # Dropout overfitting
6 model.add(Dense(n_hours_future))
7 model.compile(loss='mae', optimizer='adam')

```

Kod 6.8: Modelin oluşturulması [65]

```

1 print(model.summary())

```

Kod 6.9: Modelin yapısı [65]

```

1 history = model.fit(train_X, train_y, epochs=50, batch_size=72, validation_data=(
↪ test_X, test_y), verbose=2, shuffle=False)
2
3 plt.plot(history.history['loss'])
4 plt.plot(history.history['val_loss'])
5 plt.title('model loss')
6 plt.ylabel('loss')
7 plt.xlabel('epoch')
8 plt.legend(['train', 'test'], loc='upper left')
9 plt.show()

```

Kod 6.10: Modelden elde edilen eğitim ve test kayıpları [64]

```

1 yhat = model.predict(test_X)
2 test_X_reshaped = test_X.reshape((test_X.shape[0], n_hours_past*n_features))
3
4 from sklearn.metrics import mean_absolute_error

```

```

5 from sklearn.metrics import median_absolute_error
6 from sklearn.metrics import mean_squared_error
7 from sklearn.metrics import mean_squared_log_error
8 from sklearn.metrics import explained_variance_score
9
10 for i in range(0, n_hours_future):
11     yhat_i = yhat[:,i]
12     yhat_i = yhat_i.reshape((yhat_i.shape[0],1))
13
14     test_y_i = test_y[:,i]
15     test_y_i = test_y_i.reshape((test_y_i.shape[0],1))
16
17     y_pred = concatenate((yhat_i, test_X_reshaped[:, -(n_features-1):]), axis=1)
18     y_pred = scaler.inverse_transform(y_pred)
19     y_pred = y_pred[:,0]
20
21     y_true = concatenate((test_y_i, test_X_reshaped[:, -(n_features-1):]), axis=1)
22     y_true = scaler.inverse_transform(y_true)
23     y_true = y_true[:,0]
24
25     def rmsle(real, predicted):
26         sum=0.0
27         for x in range(len(predicted)):
28             if predicted[x]<0 or real[x]<0: #check for negative values
29                 continue
30             p = numpy.log(predicted[x]+1)
31             r = numpy.log(real[x]+1)
32             sum = sum + (p - r)**2
33         return (sum/len(predicted))*0.5
34
35     def best_fit_slope_and_intercept(y_true,y_pred):
36         m = (((mean(y_true)*mean(y_pred)) - mean(y_true*y_pred)) / ((mean(y_true)*
37 ↪ mean(y_true)) - mean(y_true*y_true)))
38         b = mean(y_pred) - m*mean(y_true)
39         return m, b
40
41     def squared_error(y_pred_orig,y_pred_line):
42         return sum((y_pred_line - y_pred_orig) * (y_pred_line - y_pred_orig))
43
44     def coefficient_of_determination(y_pred_orig,y_pred_line):
45         y_mean_line = [mean(y_pred_orig) for y in y_pred_orig]
46         squared_error_regr = squared_error(y_pred_orig, y_pred_line)
47         squared_error_y_mean = squared_error(y_pred_orig, y_mean_line)

```

```

47     return 1 - (squared_error_regr/squared_error_y_mean)
48
49     m, b = best_fit_slope_and_intercept(y_true,y_pred)
50     regression_line = [(m*x)+b for x in y_true]
51
52     r_squared = coefficient_of_determination(y_pred,regression_line)
53     evs_i = explained_variance_score(y_true, y_pred, multioutput='uniform_average')
54     rmsle_i = rmsle(y_true,y_pred)
55     rmse_i = sqrt(mean_squared_error(y_true, y_pred))
56     mae_i = mean_absolute_error(y_true, y_pred)
57     std_i = numpy.std(numpy.absolute(y_true - y_pred))

```

Kod 6.11: Normalleştirilmenin geri çevirilmesi ve hata hesaplama [66–69]

```

1     print('%d saat sonra:' % (i+1))
2     print('R2 = %.3f, EVS = %.3f, RMSLE = %.3f, RMSE = %.3f, MAE= %.3f, STD
   ↪ = %.3f' % (r_squared, evs_i, rmsle_i, rmse_i,mae_i,std_i))
3
4     pyplot.scatter(y_true,y_pred,color='#003F72',title='data')
5     pyplot.plot(y_true, regression_line, title='Regresyon Doğrusu')
6     pyplot.legend(loc=4)
7     pyplot.show()
8
9     pyplot.plot(y_true, title='Gerçek Değerler')
10    pyplot.plot(y_pred, title='Tahmin Değerler')
11    pyplot.legend()
12    pyplot.show()
13
14    print('\n')

```

Kod 6.12: Hata sonuçları [67]



# Kaynaklar

- [1] Ali Güngör. Isparta İlindeki atmosferde bulunan kükürtdioksit (so2) ve partikül madde (pm) konsantrasyonunun Çoklu doğrusal regresyon. Master's thesis, SüleymanDemirel Üniversitesi,, 2013.
- [2] Ali Güngör and H Cahit SEVİNDİR. Isparta ilindeki atmosferde bulunan kükürt dioksit (so2) ve partikül madde (pm) konsantrasyonunun çoklu doğrusal regresyon yöntemi ile modellenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 17(1), 2013.
- [3] Yıldız Teknik Üniversitesi Akademik Bilgi Sistemi.
- [4] John H Seinfeld and Spyros N Pandis. *Atmospheric chemistry and physics: from air pollution to climate change*. John Wiley & Sons, 2016.
- [5] Hüseyin Özdemir, Gülsüm Borucu, Göksel Demir, Selda Yiğit, and Namık Ak. İstanbul'daki çocuk oyun parklarında partikül madde (pm2, 5 ve pm10) kirliliğinin incelenmesi. *Ekoloji*, 20(77):72–79, 2010.
- [6] World Health Organization, UNAIDS, et al. *Air quality guidelines: global update 2005*. World Health Organization, 2006.
- [7] ASHRAE Handbook et al. Fundamentals. *American Society of Heating, Refrigerating and Air Conditioning Engineers, Atlanta*, 111, 2001.
- [8] Bilge Karakaş. İç ve dış hava ortamlarında partiküler madde (pm10, pm2.5 ve pm1) konsantrasyonlarının değerlendirilmesi. Master's thesis, Hacettepe Üniversitesi, 2015.
- [9] Sun-Chong Wang. Artificial Neural Network. In *Interdisciplinary Computing in Java Programming*, pages 81–100. Springer US, Boston, MA, 2003.
- [10] Abdullah M Alsugair and Ali A Al-Qudrah. Artificial neural network approach for pavement maintenance. *Journal of computing in civil engineering*, 12(4):249–255, 1998.

- [11] W. Sarle. Neural networks frequently asked questions. URL: <ftp://ftp.sas.com/pub/neural/FAQ.html>, 1997.
- [12] Zeynep Cansu Öztürk. Modelling of atmospheric so2 pollution in seydişehir town by artificial neural networks. Master's thesis, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, 2015.
- [13] RM Boubel. The history of air pollution. fundamentals of air pollution third edition, 1994.
- [14] P Aarne Vesilind, Susan M Morgan, and Lauren G Heine. *Introduction to Environmental Engineering-SI Version*. Cengage Learning, 2010.
- [15] Lawrence K Wang, Norman C Pereira, Yung-Tse Hung, et al. *Air pollution control engineering*, volume 1. Springer, 2004.
- [16] Jeremy Colls. *Air pollution*. CRC Press, 2002.
- [17] TC Çevre and Şehircilik Bakanlığı. Atık yönetimi eylem planı, 2008.
- [18] Zahra Shayegan, Chang-Seo Lee, and Fariborz Haghghat. Tio2 photocatalyst for removal of volatile organic compounds in gas phase—a review. *Chemical Engineering Journal*, 334:2408–2439, 2018.
- [19] Minnesota Sağlık Departmanı. Volatile organic compounds in your home.
- [20] Karl B Schnelle Jr, Russell F Dunn, and Mary Ellen Ternes. *Air pollution control technology handbook*. CRC press, 2015.
- [21] Helene Holmgren. *On the Formation and Physical Behaviour of Exhaled Particles*. Chalmers University of Technology, 2011.
- [22] Y Dumanoğlu and A Bayram. İzmir’de kent merkezi ve yakın çevresinde ölçülen ozon ve azot dioksit seviyelerinin zamansal değişiminin incelenmesi. *Hava Kirliliği Araştırmaları Dergisi*, 2:65–73, 2013.
- [23] Health and Environmental Effects of Particulate Matter (PM), <https://www.epa.gov/pm-pollution/health-and-environmental-effects-particulate-matter-pm>, görüntülenme tarihi: 2018-09-15.
- [24] Standards - Air Quality - Environment - European Commission.
- [25] Ambient (outdoor) air quality and health.
- [26] Başbakanlık Mevzuatı Geliştirme ve Yayın Genel Müdürlüğü, <http://www.resmigazete.gov.tr/eskiler/2014/12/20141220-2.htm>, görüntülenme tarihi: 2018-09-10.

- [27] Michael Copeland. What's the difference between artificial intelligence, machine learning, and deep learning. *Nvidia*, <https://blogs.nvidia.com/blog/2016/07/29/whats-differenceartificial-intelligence-machine-learning-deep-learning-ai>, 2016.
- [28] Nils J Nilsson and Nils Johan Nilsson. *Artificial intelligence: a new synthesis*. Morgan Kaufmann, 1998.
- [29] DT Pham and PTN Pham. Artificial intelligence in engineering. *International Journal of Machine Tools and Manufacture*, 39(6):937–949, 1999.
- [30] Patrick Henry. Winston. *Artificial intelligence*. Addison-Wesley Pub. Co, Reading Mass., 1993.
- [31] Avneet Pannu. Artificial intelligence and its application in different areas. *Artificial Intelligence*, 4(10):79–84, 2015.
- [32] Herbert A Simon. Artificial intelligence: an empirical science. *Artificial Intelligence*, 77(1):95–127, 1995.
- [33] Frederick A Miller, Judith H Katz, and Roger Gans. The od imperative to add inclusion to the algorithms of artificial intelligence. *OD PRACTITIONER*, 50(1), 2018.
- [34] Ercan Öztemel. *YAPAY SİNİR AĞLARI*. Papatya Yayıncılık Eğitim AŞ, 2012.
- [35] Christian Robert. Machine learning, a probabilistic perspective, 2014.
- [36] Abdulkadir Şeker, Banu Diri, and Hasan Hüseyin Balık. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3):47–64, 2017.
- [37] Dhrumil Patel. Different Types Of Machine Learning.
- [38] Zhang Hongxin. What is machine learning? *citeseerx.ist.psu.edu*, 2005.
- [39] Marcel van Gerven and Sander Bohte. *Artificial neural networks as models of neural information processing*. Frontiers Media SA, 2018.
- [40] Neural Network Definition — DeepAI, <https://deepai.org/machine-learning-glossary-and-terms/neural-network>, görüntülenme tarihi:2018-09-21.
- [41] Vanishing gradient problem, <https://en.wikipedia.org/wiki/vanishing+gradient+problem>, görüntülenme tarihi:2018-09-18.
- [42] Sun-Chong Wang. Artificial neural network. In *Interdisciplinary computing in java programming*, pages 81–100. Springer, 2003.

- [43] Andrew Fogg. A History of Deep Learning, <https://www.import.io/post/history-of-deep-learning/>, görüntülenme tarihi: 2018-10-11.
- [44] *Deep Learning for Computational Science and Engineering*, 2018.
- [45] Saurabh Rathor. Simple rnn vs gru vs lstm :- difference lies in more flexible control. <https://medium.com/@saurabh.rathor092/simple-rnn-vs-gru-vs-lstm-difference-lies-in-more-flexible-control-5f33e07b1e57>, 2018.
- [46] İbrahim Kök, Mehmet Ulvi Şimşek, and Suat Özdemir. A deep learning model for air quality prediction in smart cities. In *Big Data (Big Data), 2017 IEEE International Conference on*, pages 1983–1990. IEEE, 2017.
- [47] Vikram Narasimha Reddy and Shrestha Mohanty. Deep air : Forecasting air pollution in beijing , china. In *semanticscholar*, 2017.
- [48] V Athira, P Geetha, R Vinayakumar, and KP Soman. Deepairnet: Applying recurrent networks for air quality prediction. *Procedia Computer Science*, 132:1394–1403, 2018.
- [49] Xiang Li, Ling Peng, Yuan Hu, Jing Shao, and Tianhe Chi. Deep learning architecture for air quality predictions. *Environmental Science and Pollution Research*, 23(22):22408–22417, 2016.
- [50] Zhongang Qi, Tianchun Wang, Guojie Song, Weisong Hu, Xi Li, and Zhongfei Mark Zhang. Deep air learning: Interpolation, prediction, and feature analysis of fine-grained air quality. *IEEE Transactions on Knowledge and Data Engineering*, 2018.
- [51] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *nature*, 521(7553):436, 2015.
- [52] Junyoung Chung, Caglar Gulcehre, KyungHyun Cho, and Yoshua Bengio. Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*, 2014.
- [53] Chao Zhang, Junchi Yan, Changsheng Li, Xiaoguang Rui, Liang Liu, and Rongfang Bie. On estimating air pollution from photos using convolutional neural network. In *Proceedings of the 2016 ACM on Multimedia Conference*, pages 297–301. ACM, 2016.
- [54] Tien-Cuong Bui, Van-Duc Le, and Sang-Kyun Cha. A deep learning approach for air pollution forecasting in south korea using encoder-decoder networks & lstm. *arXiv preprint arXiv:1804.07891*, 2018.

- [55] 2016 genel nüfus sayımı verileri, <https://biruni.tuik.gov.tr/medas/> , görüntülenme tarihi: 2018-09-23.
- [56] Keçiören, <https://tr.wikipedia.org/wiki/keçiören>, görüntülenme tarihi: 2018-09-23.
- [57] SİM (Sürekli İzleme Merkezi) — T.C ÇEVRE VE ŞEHİRCİLİK BAKANLIĞI, <http://www.havaizleme.gov.tr/services/airquality>, görüntülenme tarihi: 2018-09-23.
- [58] Ankara hava kirliliği, <https://emlakkulisi.com/guncel/ankara-hava-kirliligi/983609>, görüntülenme tarihi: 2018-09-23.
- [59] İLİMİZDE BULUNAN HAVA KALİTESİ ÖLÇÜM İSTASYONLARININ YERİNDE TESPİTLERİ VALİ YARDIMCIMIZ MEHMET KURT BAŞKANLIĞINDA YAPILMIŞTIR.
- [60] ANKARA - İklim ve Bitki Örtüsü, <http://www.cografya.gen.tr/tr/ankara/iklim.html>, görüntülenme tarihi: 2018-09-23.
- [61] İklim: Keçiören - İklim grafiği, Sıcaklık grafiği, İklim tablosu - Climate-Data.org.
- [62] Wes McKinney. pandas: a foundational python library for data analysis and statistics. *scribd*, 2011.
- [63] J. D. Hunter. Matplotlib: A 2d graphics environment. *Computing In Science & Engineering*, 9(3):90–95, 2007.
- [64] Jason Brownlee. Machine Learning Mastery.
- [65] François Chollet et al. Keras. <https://keras.io>, 2015.
- [66] Mohammed Kashif. python - Root mean log squared error issue with scitkit-learn.ensemble.GradientBoostingRegressor - Stack Overflow.
- [67] Shaobin675. Linearregression - pythonexample.com, <https://pythonexample.com/code/linearregression/>, görüntülenme tarihi: 2018-09-27.
- [68] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.

- [69] Travis E. Oliphant. *Guide to NumPy*. CreateSpace Independent Publishing Platform, USA, 2nd edition, 2015.



# ÖZGEÇMİŞ

## Kişisel Bilgiler

Soyadı, adı : AYTURAN, Yasin Akın  
Uyruğu : TC  
Doğum tarihi ve yeri : 09/09/1990 - Ankara  
Medeni Hali : Evli  
Tel : +90 554 867 56 60  
Fax : -  
E-mail : akinayturan@gmail.com

## Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek Lisans	: KTO Karatay Üniversitesi	-
Lisans	: Başkent Üniversitesi	Temmuz-2015
Lise	: Gazi Üniversitesi Vakfı Fen Lisesi	Haziran-2007

## İş Deneyimi

Yıl	Yer	Görev
2016-Devam	Pardus Ajans	Yazılım geliştirici
2015-2016	Tan Teknoloji	Yazılım geliştirici
2014-2014	Ventura Yazılım	Stajyer Mühendis
2013-2013	TUSAŞ	Stajyer Mühendis

## Yabancı Dil

İngilizce (İyi), Almanca (Başlangıç)

## Yayımlar

Makale(ler)

- Air Pollution Modelling with Deep Learning: A Review - Yasin Akın Ayturan, Zeynep Cansu Ayturan, Hüseyin Oktay Altun - International Journal of Environmental Pollution and Environmental Modelling, Vol. 1(3): ss 58-62 (2018)

- Modelling of PM10 Pollution in Karatay District of Konya with Artificial Neural Networks - Yasin Akın Ayturan, Ali Öztürk, Zeynep Cansu Ayturan - Journal of International Environmental Application and Science, Vol. 12(3): ss 256-263 (2017)

#### Bildiri(ler)

- Air Pollution Modelling With Deep Learning - Yasin Akın Ayturan, Zeynep Cansu Ayturan, Hüseyin Oktay Altun - International Conference of Ecosystems, Proceedings Book ICE2018: ss 301-305

