



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

KABİL'İN HAVA KALİTESİ TAHMİNİNDE MAKİNE ÖĞRENMESİ
ALGORİTMALARININ KULLANILMASI

SAKHIDAD FAIZI

Eylül 2021

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

KABİL'İN HAVA KALİTESİ TAHMİNİNDE MAKİNE ÖĞRENMESİ
ALGORİTMALARININ KULLANILMASI

SAKHIDAD FAIZI

Yüksek Lisans Tezi

Danışman
Prof. Dr. Fehiman ÇİNER

İkinci Danışman
Dr. Öğretim Üyesi Ahmet Emin KARKINLI

Eylül, 2021

Saklıdad FAIZI tarafından **Prof. Dr. Fehiman ÇİNER** ve **Dr. Öğretim Üyesi Ahmet Emin KARKINLI** danışmanlıklarında hazırlanan “Kabil’in Hava Kalitesi Tahmininde Makine Öğrenmesi Algoritmalarının Kullanılması” adlı bu çalışma jürimiz tarafından Niğde Ömer Halisdemir Üniversitesi Fen Bilimleri Enstitüsü **Çevre Mühendisliği** Ana Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan : Doç. Dr. Nevzat BEYAZIT (Ondokuz Mayıs Üniversitesi)

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

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

Üye : Dr. Öğr. Üyesi Tuba KURBAN (Gazi Üniversitesi)

Üye : Dr. Öğr. Üyesi Ahmet Emin KARKINLI (Niğde Ömer Halisdemir Üniversitesi)

ONAY:

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

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

Prof. Dr. Murat BARUT
MÜDÜR

TEZ BİLDİRİMİ

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

Sakhidad FAIZI



ÖZET

KABİL’İN HAVA KALİTESİ TAHMİNİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARININ KULLANILMASI

FAIZI, Sakhidad

Niğde Ömer Halisdemir Üniversitesi

Fen Bilimleri Enstitüsü

Çevre Mühendisliği Anabilim Dalı

Danışman : Prof. Dr. Fehiman ÇİNER

İkinci Danışman : Dr. Öğretim Üyesi Ahmet Emin KARKINLI

Eylül 2021, 96 sayfa

Günümüzde, insanların çeşitli faaliyetleri sonucu meydana gelen üretim ve tüketim aktiviteleri sırasında ortaya çıkan hava kirliliği her gün artan bir çevre sorunudur. Bu sorun, atmosferdeki hava bileşiklerinin değişmesi, küresel iklim değişimi, asit yağışları, ozon tabakasının seyrelmesi, yaban hayatı ve insanlar üzerindeki olumsuz etkiler oluşturarak ekosisteme zarar vermektedir. Hava kirliliğini etkileyen parametrelerin belirlenerek bir model içerisinde değerlendirilmesi, kirliliğe karşı alınabilecek önlemleri yönlendirebilmekte ve hava kalitesi ve standartlarının iyileştirilebilmesi için üretilecek çözüm süreçlerini kolaylaştırmaktadır. Hava kirliliğinin birçok parametreye bağlı olması, her parametrenin ölçülememesi/temin edilememesi bu konuda makine öğrenmesi tekniklerinin kullanılmasının temel nedenidir. Bu tez çalışmasında da Kabil iline ait Sıcaklık, Çiy noktası, Nem, Rüzgâr Hızı ve Basınç meteoroloji parametreleri ile $PM_{2.5}$, PM_{10} , CO, SO_2 , NO_2 , O_3 kirleticilerinden oluşan bir veri seti kullanılmıştır. Veri seti literatürde iyi bilinen, Lineer Regresyon, Yapay Sinir Ağları, Destek Vektör Makinaları, Karar Ağaçları ve Gauss Süreç Regresyonu yöntemleriyle modellenmiş ve modellerin başarısı karşılaştırılmıştır.

Anahtar Kelimeler: Hava kirliliği, makine öğrenmesi, Kabil, karbon monoksit, kükürt dioksit, partikül madde

SUMMARY

USING MACHINE LEARNING ALGORITHMS IN PREDICTION OF AIR QUALITY IN KABUL

FAIZI, Sakhidad

Niğde Ömer Halisdemir University

Graduate School of Natural And Applied Sciences

Department of Environment Engineering

Supervisor : Professor Dr. Fehiman ÇİNER

Co- supervisor : Assistant Prof. Dr. Ahmet Emin KARKINLI

Eylül 2021, 96 sayfa

Today, air pollution that occurs during production and consumption activities that occur as a result of various activities of people is an environmental problem that is increasing day by day. This problem harms the ecosystem by creating changes in air compounds in the atmosphere, global climate change, acid precipitation, depletion of the ozone layer, adverse effects on wildlife and humans. Determining the parameters affecting air pollution and evaluating them in a model can guide the measures that can be taken against pollution and facilitate the solution processes to be produced in order to improve air quality and standards. The fact that air pollution depends on many parameters and that every parameter cannot be measured/provided is the main reason for using machine learning techniques in this regard. In this thesis, a data set consisting of the temperature, dew point, humidity, wind speed and pressure meteorological parameters of the province of Kabul and pollutants $PM_{2.5}$, PM_{10} , CO, SO_2 , NO_2 , O_3 was used. The data set was modeled with the well-known methods of Linear Regression, Artificial Neural Networks, Support Vector Machines, Decision Trees and Gaussian Process Regression and the success of the models was compared.

Keywords: Air pollution, Machine Learning, Kabul, carbon monoxide, sulfur dioxide, particulate matter

ÖN SÖZ

Yüksek lisans tez çalışmamın hazırlanması esnasında, her konuda desteğini esirgemeyen eğitim hayatımda büyük emeği olan saygıdeğer danışmanlarım Prof. Dr. Fehiman ÇİNER ve Dr. Öğr. Üyesi Ahmet Emin KARKINLI' ya teşekkürü borç bilirim.

Ayrıca; çalışmalarım süresince sabır göstererek beni daima destekleyen; yoğun çalışma dönemlerinde desteğini hep hissettiğim aileme en içten sevgi ve şükranlarımı sunarım.



İÇİNDEKİLER

ÖZET	iv
SUMMARY	v
ÖN SÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
SİMGE VE KISALTMALAR	xiii
BÖLÜM I GİRİŞ	1
BÖLÜM II HAVA KİRLİLİĞİ HAKKINDA GENEL BİLGİLER	3
2.1 Hava Kirliliği	3
2.2 Hava Kirliliğinin Kaynakları	4
2.3 Hava Kirliliğine Neden Olan Kirleticiler.....	5
2.3.1 Karbondioksit (CO ₂)	5
2.3.2 Karbon monoksit (CO)	6
2.3.3 Kükürtdioksit (SO ₂)	6
2.3.4 Azot oksitler (NO _x)	7
2.3.5 Ozon (O ₃)	7
2.3.6 Partikül Madde (PM)	8
2.4 Kirleticilerin İnsan Sağlığına Etkileri	8
2.5 Hava Kirliliğini Etkileyen Faktörler	11
2.5.1 Meteorolojik faktörler	11
2.5.2 Atmosferik şartlar (inversiyon).....	13
2.5.3 Topoğrafik faktörler.....	13
2.5.4 Kentleşme	13
2.5.5 Sanayileşme	14
2.5.6 Sosyo-ekonomik yapı.....	14
2.6 Kirleticilerin Atmosferde Hareketleri	14
2.7 Hava Kalite İndeksi ve Hesaplanması	16
2.8 Hava Kalitesi Standartları	18
2.9 Literatür Araştırması.....	19
2.10 Dünyada ve Kabil’de Hava Kirliliği	24
2.10.1 Dünya’da hava kirliliği	24
2.10.2 Kabil’in hava kirliliği.....	27

2.10.3 Kabil'in hava kirliliğinin kaynakları.....	29
2.10.3.1 Nüfus artışı	30
2.10.3.2 Sanayi faaliyetleri	30
2.10.3.3 Trafik faaliyetleri.....	31
2.10.3.4 Katı atık üretimi.....	32
BÖLÜM III MAKİNE ÖĞRENMESİ ALGORİTMALARI	33
3.1 Makine Öğrenmesi Kavramı.....	33
3.2 Makine Öğrenmesi Algoritmaları	34
3.2.1 Lineer regresyon	34
3.2.2 Yapay sinir ağları.....	35
3.2.2.1 Yapay sinir ağları öğrenme stratejileri	38
3.2.3 Destek Vektör Makineleri.....	39
3.2.3.1 Lineer ayrılabilme durumu	39
3.2.3.1 Lineer ayrılmama durumu	41
3.2.4 Karar ağaçları.....	43
3.2.4.1 Karar ağaçlarının oluşturulması.....	44
3.2.4.2 Sınıflandırma ve regresyon ağaçları (CART).....	45
3.2.4.2.1 Gini indeksi.....	45
3.2.4.2.2 Twoing kuralı.....	46
3.2.4.3 Karar ağaçlarında dallanma kriterleri	47
3.2.4.3.1 Entropi bazlı algoritmalar	47
3.2.5 Gauss süreç regresyonu.....	48
BÖLÜM IV MATERYAL VE YÖNTEM	51
4.1 Çalışma Alanının Tanıtımı.....	51
4.1.1 Coğrafi konumu	51
4.1.2 Kent nüfusu.....	52
4.1.3 İklim özellikleri.....	52
4.2 Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini	55
BÖLÜM V UYGULAMA VE BULGULAR.....	56
5.1 Veri Seti ve Verilerin Normalizasyonu	56
5.2 Model ve Değerlendirme	58
5.2.1 Lineer regresyon ile HKİ tahmini	59
5.2.2 Yapay sinir ağları ile HKİ tahmini.....	61
5.2.3 Destek vektör makineleri ile HKİ tahmini.....	63
5.2.4 Karar ağaçları ile HKİ tahmini	64
5.2.5 Gauss süreç regresyonu ile HKİ tahmini	66
5.2.6 Makine öğrenmesi algoritmaları model sonuçları	67

BÖLÜM VI SONUÇLAR	70
KAYNAKLAR	73
EKLER.....	84
ÖZ GEÇMİŞ	96



ÇİZELGELER DİZİNİ

Çizelge 2.1. Bazı hava kirliliği olayları ve sonuçları (Bıyık, 2010)	9
Çizelge 2.2. Kirletici parametreler ve sağlık etkileri (URL 2)	11
Çizelge 2.3. EPA HKİ (URL 2)	17
Çizelge 2.4. Ulusal Hava Kalitesi Değerleri Kesme (Kırılma) Noktaları (URL 2).....	18
Çizelge 2.5. Hava kalitesi parametrelerinin sınır değerleri (URL1; URL2).....	19
Çizelge 2.6. 2005 yılında Kabil'in toplam tahmini yıllık emisyonları	29
Çizelge 2.7. Afganistan'daki aktif sanayi şirketlerinin sayısı (NEPA, 2012)	31
Çizelge 3.1. Destek Vektör Makineleri kernel fonksiyonları	43
Çizelge 3.2. Gauss süreci kernel fonksiyonları.....	50
Çizelge 4.1. Kabil'de hava kirliliği ölçüm istasyon yerleri ve ölçülen parametreler	54
Çizelge 5.1. Hesaplanmış regresyon katsayıları	60
Çizelge 5.2. Lineer regresyon performans ölçütleri	60
Çizelge 5.3. Yapay sinir ağları performans ölçütleri	62
Çizelge 5.4. Destek vektör makineleri performans ölçütleri	63
Çizelge 5.5. Karar ağaçları performans ölçütleri	65
Çizelge 5.6. Gauss süreç regresyonu performans ölçütleri.....	66
Çizelge 5.7. Makine öğrenmesi algoritmaları eğitim ve test sonuçları	67
Çizelge 5.8. Tüm veriler için makine öğrenmesi algoritmaları sonuçları	67
Çizelge 5.9 Meteorolojik parametreler ile hava kalite indeksi arasındaki korelasyon katsayıları	68

ŞEKİLLER DİZİNİ

Şekil 2.1. Kuzey yarım kürede bir siklonda yakınsayan rüzgarların düşük irtifa saat yönü tersindeki spiralleri.....	15
Şekil 2.2. Kuzey yarım kürede bir antisiklondan uzaksayan rüzgarların saat yönündeki spiralleri	16
Şekil 2.3. Dünya’da ülkelerin gelir dağılımına göre 2010’dan 2016 yılına doğru hava kirliliği değişimi.....	26
Şekil 2.4. PM2.5 konsantrasyonunun en yüksek olduğu ülkeler	27
Şekil 2.5. Afganistan’da araç sayısı artışı (Agerskov, 2013).....	32
Şekil 3.1. Basit doğrusal regresyon grafiği.....	34
Şekil 3.2. Biyolojik sinir hücresinin yapısı.....	36
Şekil 3.3. Yapay sinir hücresi	36
Şekil 3.4. Yapay sinir ağı aktivasyon fonksiyonları (Elliott, 1993)	38
Şekil 3.5. Lineer olarak ayrılabilen veriler için optimum ayırıcı yüzey	40
Şekil 3.6. Lineer ayrılamama durumundaki veriler	41
Şekil 3.7. Lineer olmayan verilerin yüksek boyutlu uzayda ayrılması.....	42
Şekil 3.8. Karar ağaçları gösterimi	44
Şekil 4.1. Afganistan’ın coğrafi konumu.....	51
Şekil 4.2. Kabil’ in birinci bölgesi	53
Şekil 5.1. Afganistan Ulusal Çevre Ajansı’ndan alınmış örnek kirlilik verileri.....	56
Şekil 5.2. 2019, 2020, 2021 yıllarına ait aylık ortalama HKİ değerleri.....	57
Şekil 5.3. HKİ tahmini için oluşturulan model yapısı	59
Şekil 5.4. Eğitim ve test verileri	59
Şekil 5.5. Eğitim verisinin lineer regresyonla tahmin edilen ve ölçülen hava kalite indeksi değerleri.....	61
Şekil 5.6. Test verisinin lineer regresyonla tahmin edilen ve ölçülen hava kalite indeksi değerleri	61
Şekil 5.7. Yapay sinir ağ modeli.....	62
Şekil 5.8. Eğitim verisinin yapay sinir ağlarıyla tahmin edilen ve ölçülen hava kalite indeksi değerleri.....	62

Şekil 5.9. Test verisinin yapay sinir ağlarıyla tahmin edilen ve ölçülen hava kalite indeksi değerleri.....	63
Şekil 5.10. Eğitim verisinin destek vektör makineleri ile tahmin edilen ve ölçülen hava kalite indeksi değerleri.....	64
Şekil 5.11. Test verisinin destek vektör makineleri ile tahmin edilen ve ölçülen hava kalite indeksi değerleri.....	64
Şekil 5.12. Eğitim verisinin karar ağaçları ile tahmin edilen ve ölçülen hava kalite indeksi değerleri.....	65
Şekil 5.13. Test verisinin karar ağaçları ile tahmin edilen ve ölçülen hava kalite indeksi değerleri	65
Şekil 5.14. Eğitim verisinin gauss süreç regresyonu ile tahmin edilen ve ölçülen hava kalite indeksi değerleri.....	66
Şekil 5.15. Test verisinin gauss süreç regresyonu ile tahmin edilen ve ölçülen hava kalite indeksi değerleri.....	67
Şekil 5.16. Korelasyon Matrisi	69

SİMGE VE KISALTMALAR

Simgeler

CO ₂	Karbon dioksit
CO	Karbon monoksit
PM	Partikül madde
NO _x	Azot oksitler
O ₃	Ozon
SO ₂	Kükürt dioksit

Açıklama

Kısaltmalar

HKİ	Hava Kalite İndeksi
DVM	Destek Vektör Makineleri
GPR	Gauss Süreç Regresyonu
YSA	Yapay Sinir Ağları

Açıklama

BÖLÜM I

GİRİŞ

Hava, atmosferde bulunan bir dizi gazdan oluşmaktadır. Hava, tüm canlıların hayatta kalmasındaki en önemli unsurlardan biridir. Bir insanın günde ortalama 1,5 kg besine, 10-20 metreküp havaya ve 2,5 litre suya ihtiyacı vardır. Bir insan 6 gün susuzluğa, 60 gün açlığa dayanabilir ama havasızlığa 6 dakikadan fazla dayanamaz. Dış atmosferdeki toz, sis, koku, gaz, duman veya buhar gibi bir veya daha fazla kirletici insanlara, hayvanlara, bitkilere veya eşyalara zarar verebilecek miktarlarda hava kirliliğine neden olabilir (Nuhoğlu, 2014).

Nüfusun büyük bir kısmı hava kalitesi standartlarının bazen aşıldığı sanayi şehirlerinde yaşamaktadır. Hava kirliliğinin çözümü ile ilgili ilk çalışmalar 1950'lerde endüstriyel gelişme ile başlamıştır. Bu bağlamda, hava kirliliğinin yüksek olduğu ülkelerde çeşitli STK'lar, üniversiteler, kurumlar ve kuruluşlar faaliyete başlamıştır. Kirliliğin ekonomik olarak kontrol edilemediği ancak kontrol edilebileceği ileri sürülmektedir. Bu dönemde başlayan hava kirliliği sorunu günümüzde de devam etmekte ve geleceği tehdit etmektedir (EPA, 2019).

Kentsel alanlarda nüfusun, trafiğin, konut sayısının ve sanayileşmenin hızla artması ile ortam havasındaki çeşitli kirleticilerin miktarı artmakta ve bu da hava kalitesini kötüleştirmektedir. Hava kirliliği ısınma döneminin başladığı kış aylarında artış göstermektedir. Isınmadan kaynaklanan hava kirliliğinin temel nedenleri; kalitesiz fosil yakıtların kullanımı, artan kömür kullanımı, yanlış yakma tekniklerinin uygulanması, kazan işletme bakımının düzenli yapılmaması ve yakıt fiyatlarındaki politikalardır (Kunt, 2014).

1.1 Çalışmanın Amacı ve Önemi

Hava kirliliği, hava ortamındaki katı, sıvı ve gaz şeklindeki her türlü kirleticinin insan sağlığına, canlı hayatına ve ekolojik dengeye zarar verebilecek düzeyde ve sürede bulunmasıdır (Ashoor, 2019). Noktasal ve çizgisel emisyon kaynakları gibi çeşitli kaynaklardan gelen kirleticiler, doğal veya insan aktiviteleri sonucunda hava ortamında

fiziksel ve kimyasal olarak karışırlar. Hava kirliliğine sebep olan ve hava ortamında bulunan en yaygın kirleticiler kükürt dioksit (SO₂), azot oksit (NO_x), karbon monoksit (CO), Ozon (O₃), hidrokarbon (HC) ve partikül madde (PM)'dir (Tel, 2019; Karakuş ve Yıldız, 2019).

Meteorolojik şartlara bağlı olarak taşınan, çeşitli kaynaklardan yayılan veya bir bölgede toplanan hava kirleticileri, taşınma sırasında seyrelir ya da fotokimyasal reaksiyonlara uğrar. Hava kirliliği küresel bir boyutta olmakla birlikte, büyük ölçüde bölgesel nedenlere dayanmaktadır. Bu nedenle çözüm önerilerinin bölgesel ölçekte dikkate alınması öngörülmektedir (Kunt, 2014).

Hava kirletici parametreler ile meteorolojik faktörler arasında yakın bir ilişki mevcut olup, meteorolojik değişkenler ve gözlenen kirletici seviyeleri arasındaki ilişkilerin anlaşılması, kirlilik projeksiyonlarının geliştirilmesi açısından da oldukça önemlidir. Regresyon analizine dayalı olarak meteorolojik parametreler ile hava kalite parametreleri ve hava kalite indeksi (HKİ) arasındaki ilişkileri ortaya koymak için son yıllarda çok sayıda çalışma yapılmıştır (Karakuş ve Yıldız, 2019).

Bu tez çalışmasında, Afganistan İslam Cumhuriyeti'nin başkenti Kabil şehrine ait Sıcaklık, Çiy noktası, Nem, Rüzgar Hızı ve Basınç gibi meteorolojik parametreler ile PM_{2.5}, PM₁₀, CO, SO₂, NO₂, O₃ kirleticilerinden oluşan bir veri seti kullanılarak, literatürde iyi bilinen Lineer Regresyon, Yapay Sinir Ağları, Destek Vektör Makinaları, Karar Ağaçları ve Gauss Süreç Regresyonu gibi makine öğrenmesi algoritmaları kullanılarak hava kalite indeksini tahmin eden modellerin tasarlanması amaçlanmıştır.

BÖLÜM II

HAVA KİRLİLİĞİ HAKKINDA GENEL BİLGİLER

2.1 Hava Kirliliği

Atmosfer, yer küresinin etrafını kaplayan ince bir gaz karışımından oluşmaktadır (Türküm, 2018). Atmosfer, dünyayı düzenleyen ve koruyan bir örtüdür (Kırmacı, 2019). Atmosferik havanın hacme göre %1–3‘ü su buharı olup, %78,1‘i (hacimce) azot, %21‘i oksijen, %0,9‘u argon ve %0,03‘ü karbondioksitten oluşmaktadır. Buna ilaveten, hava, %0,002‘nin altındaki seviyelerde çeşitli iz seviye gazları (neon, helyum, metan, kripton, azot oksit, hidrojen, ksenon, kükürt dioksit, ozon, azot dioksit, amonyak ve karbon monoksit gibi) içerir (Williamson, 1973; Türküm, 2018).

Atmosferde bulunan gazlar üç grupta incelenmektedir (Kırmacı, 2019).

1. Havada her zaman bulunan ve miktarları değişmeyen gazlar (oksijen, azot ve asal gazlar).
2. Havada her zaman bulunan ve miktarları artan veya azalan gazlar (su buharı, karbondioksit, ozon)
3. Havada her zaman bulunmayan gazlar (kirleticiler).

Hava kirliliği, havanın doğal bileşeninde bulunan maddelerin oranlarının değişmesi, canlı hayatını olumsuz etkileyen ve/veya çevresel dengeye maddi zarar verebilecek her türlü kirleticinin normalin üzerinde bir miktar, yoğunluk ve sürede hava ortamında bulunmasıdır (Akyürek vd., 2013; Kırmacı, 2019; Altıntaş, 2020). Hava kirliliğinin ortaya çıkması ile yaşam kalitesinin düşmesi, çevre problemlerinin artması, ekolojik ve doğal dengenin bozulması gibi tehlikelerle tüm canlılar karşı karşıyadır. Yaşlanan dünya, gelişen sanayileşme, artan enerji ihtiyacı ve yüksek katlı binalar ile özellikle insanlar olmak üzere tüm canlılar üzerinde olumsuz ve yıkıcı etkilere yol açmaktadır (Tel, 2019).

Hava kirliliği izlemede kentsel kirleticiler olarak bilinen kükürt dioksit (SO₂), kurşun (Pb), hidrokarbonlar (HC), karbon monoksit (CO) ve partikül madde (PM) gibi kirleticiler motorlu taşıtlar ve fosil yakıtlardan kaynaklanmaktadır (Kırmacı, 2019).

2.2 Hava Kirliliğinin Kaynakları

Hava kirliliğinin pek çok kaynağı olmakla birlikte, doğal veya antropojenik kaynaklardan gaz, toz veya sıvı halde atmosfere atılan maddelerin doğrudan veya dolaylı olarak diğer maddelerle reaksiyona girmesiyle oluşmaktadır (Bıyık, 2010; Altıntaş, 2020).

1. **Doğal kaynaklar:** Atmosferde meydana gelen doğa olayları sonucunda oluşan orman yangınları, volkanik patlamalar, toz fırtınaları, okyanus spreyleri, bitkilerden salınan organik bileşikler gibi insan müdahalesi olmadan hava kirliliğine neden olan olaylardır.
2. **Antropojenik kaynaklar:** Bilinçsiz kentleşme ve sanayileşme ile birlikte insan faaliyetleri sonucu meydana gelen kirliliktir. Atmosferde salınım süresi uzun ve tehlikeli olan bu kaynaklar; enerji santralleri, taşıt motorları, konutların ısınması ve endüstriyel faaliyetlerdir (Altıntaş, 2020).

Antropojenik kaynaklar ise alansal, çizgisel ve noktasal olmak üzere üç alt gruba ayrılmaktadır (Bıyık, 2010).

- ✓ **Alansal kaynaklar:** Kirleticiler iki boyutlu kaynaklardan atmosfere yayılmaktadır. Hava kirliliğinin en önemli kaynaklarından biri, ısınma amacıyla konutlarda kullanılan fosil yakıtlardır. Evsel ısınma amacıyla yakılan fosil yakıt emisyonları, yüksek oranda kükürt ve kül içeren düşük kalorili yakıtların kullanılması, ısıtma sistemlerinde yanmanın tam olmaması gibi faktörler ile meteorolojik etmenler bir araya gelerek, daha çok kış aylarında yüksek seviyede hava kirliliğine neden olmaktadır.
- ✓ **Çizgisel kaynaklar:** Kirleticiler tek boyutlu kaynaklardan atmosfere yayılmaktadır. Ulaşım amacıyla kullanılan yolcu ve yük taşıyan araçlardan yayılan emisyonlardan oluşmaktadır. Bu araçlar, içten yanmalı motorlar, dizel, benzin ve gaz türbinleri ile çalışmaktadır. Bu kaynaklardan azot oksitler, karbon monoksit, hidrokarbonlar, kükürt oksitler ve partikül maddeler gibi kirleticiler yanma sonucu atmosfere verilmektedir.
- ✓ **Noktasal kaynaklar:** Sanayi, yakma tesisleri, enerji santralleri ve fabrikalar gibi tek bir kaynaktan kirleticiler atmosfere yayılmaktadır. Enerjinin elde edilmesi

iin kullanılan yakıtların yanması sonucu atmosfere kirleticiler ıkmaktadır. Fırınlarda ve aık sahalarda katı atıkların yakılması sonucu kirlenme oluřmaktadır.

Antropojenik kaynaklar ayrıca sabit ve hareketli kaynaklar řeklinde sınıflandırılır (Kırmacı, 2019).

- ✓ **Sabit kaynaklar:** Isınma ve üretim amalı faaliyetlerden oluřmaktadır.
- ✓ **Hareketli kaynaklar:** Trafikte kullanılan araçlardan oluřmaktadır.

2.3 Hava Kirliliğine Neden Olan Kirleticiler

Atmosferdeki mevcut kirleticiler kaynaktan ıkıřlarına gre birincil ve ikincil kirleticiler olarak sınıflandırılmaktadır. Birincil kirleticiler, doėrudan bir kaynak tarafından atmosfere salınan slfr dioksit, hidrokarbon, azot oksitler, karbon monoksit, karbon dioksit, metan, partikl madde vb. bileřiklerdir/kirleticilerdir (Mangır, 2014; Altıntaş, 2020). İkincil kirleticiler, bir kaynak tarafından doėrudan atmosfere salınmayıp, havaya karışan birincil kirleticilerin havada mevcut diėer bazı trlerle atmosferde reaksiyona girmesiyle oluřan ozon, kkrt trioksit, slfrik asit, ketonlar, aldehitler ve asitler gibi reaksiyon artıklarıdır (Mangır, 2014). Partikl maddeler hem birincil hem de ikincil kirleticiler sınıfına dahil edilebilir (Altıntaş, 2020).

nemli bazı hava kirleticileri hakkında ařaėıda bilgi verilmiřtir.

2.3.1 Karbondioksit (CO₂)

Karbondioksit atmosferde %0-0.03 arasında dřk konsantrasyonlarda bulunan ve yařamsal nemi olan kritik gazlardan biridir. Bir milyon hava moleklnde yaklaşık 350 karbondioksit molekl bulunur. Atmosfere karışan karbondioksitin yaklaşık % 80-85'i kmr, doėal gaz, petrol ve trevleri gibi fosil yakıtların yanması sonucunda atmosfere verilmekte, % 15-20'si de canlının solunumu ve mikroskobik canlının organik maddeleri ayrıştırmasından kaynaklanmaktadır. Karbondioksit miktarının artması atmosferin ısınmasına neden olarak sera etkisini her geen gn arttırmaktadır. Karbondioksit yoėunluėunun atmosferde iki katına ıkması halinde sıcaklık ortalama 3°C artacaėından, kresel ısınmanın nlenebilmesi iin karbon dioksit salınımının

azaltılması tedbirleri alınmakta ve bu alanda uluslararası düzeyde çabalar harcanmaktadır (Sağlar, 2019).

2.3.2 Karbon monoksit (CO)

Karbon monoksit (CO), havanın ortalama mol ağırlığına yakın mol ağırlığında, karbon içeren yakıtların eksik yanmasıyla üretilen renksiz, kokusuz ve tatsız bir gazdır. Karbon monoksit, oksijen eksikliği, yüksek sıcaklıkta gazın kalıcılık zamanı ve yanma odası türbülansı gibi etkenlerden birinin eksikliğinde tam olmayan yanmadan dolayı ortaya çıkan birincil hava kirleticilerdendir. Atmosferde kolay kolay yok olmayan gazın ortalama kalıcılık süresi 2-4 ay olup, yarılanma ömrü oldukça uzundur. Atmosferde bulunan karbon monoksidin kandaki vücut hücrelerinin oksijen taşıma kabiliyetini azaltması gibi insan sağlığına önemli etkileri bulunmaktadır. (Kunt, 2014; Sarı, 2019). Dünyadaki karbon monoksit üretiminin %70'inden fazlası ulaşım sektöründen kaynaklanmaktadır. Atmosferde 0,03 ppm artışa neden olması yanında karbon monoksit vücuttaki oksijen miktarını azaltarak ölümlere yol açabilmektedir (İncecik, 1994).

2.3.3 Kükürtdioksit (SO₂)

Yanıcı olmayan, renksiz, boğucu ve asidik gaz halinde olan SO₂ hava ortamındaki birincil kirleticilerdendir. Atmosferde 40 güne kadar kalan SO₂'nin havadaki varlığının en önemli nedeni insan aktivitelerinin oluşturduğu yapay kaynaklar, olmasına rağmen, orman yangınları, volkan patlamaları gibi doğal kaynaklardan da az miktarda SO₂ havaya verilmektedir (Özdemir, 2008; Kırmacı, 2019). İnsanlar tarafından oluşturulan SO₂'nin havadaki varlığının en önemli nedeni, insan aktiviteleri sonucu ısınma, termik santrallerde enerji üretimi ve motorlu taşıtlar için kükürt içeren fosil yakıtların yanmasıdır (URL 1; Altıntaş, 2020). SO₂ gazının % 80'inden fazlası noktasal baca kaynaklı endüstriyel faaliyetlerden gelmekte, havadaki su ile birleşmesinin bir sonucu olarak sülfüroz asit ve daha sonra sülfürik asit oluşturarak, yağmur damlları ile yeryüzünde açık yapılarda ve eserlerde korozyona neden olarak ülke ekonomisine zarar vermekte ve sera etkisi ile yerküre sıcaklığının artışına neden olmaktadır (Kırmacı, 2019; Tel, 2019).

2.3.4 Azot oksitler (NO_x)

Azot oksitler (NO_x) yüksek sıcaklıklarda oluşan oldukça reaktif, renksiz ve kokusuz havadaki en önemli kirletici gazlardandır. NO_x, genellikle azot monoksit (NO), azot dioksit (NO₂) ve diazot monoksit (N₂O), nitrik asit ve nitrat gibi değişik bileşikler şeklinde bulunurlar (Altıntaş, 2020). Bunlardan NO ve NO₂ en önemli kirletici gazlardandır gerek atmosferdeki derişimi gerekse özelliğı nedeni ile insan sağığına olumsuz etki gösteren azot bileşigi NO₂'dir (Kırmacı, 2019; Tel, 2019). NO_x'lerin büyük bir kısmı trafikteki araçların egzozları, insineratörler, kimyasal işlemler, ısınma amacıyla kullanılan fosil yakıtların yanması ve elektrik üretimi gibi faaliyetlerden kaynaklanmaktadır. Bu aktivitelerden dış ortama verilen renksiz, kokusuz ve zararsız olan NO atmosferde oksidasyon sonucu hızla kokulu ve zararlı bir gaz olan NO₂'ye oksitlenir (Kırmacı, 2019). Her iki gaz da doğal azot çevriminin birer parçasıdır. Asit yağışlarına katkılarının yanı sıra, fotokimyasal sisin oluşumunda da başlıca etkenlerden sayılırlar. NO_x gazları NO₂ eşdeğeri ile tanımlanır. Atmosferdeki yarılanma ömürleri düşük olup, normalde dünya atmosferinde 1 ppb'den daha az konsantrasyonda olmaları beklenir. Oysa kentsel atmosferde bu derişimler 40-80 ppb hatta 300-1400 ppb seviyelerine kadar yükselmektedir (Kunt, 2014).

Son zamanlarda evsel ısınma ve endüstriyel faaliyetlerde kömür kullanımı azaltılarak doğalgaz kullanımına geçiş ile azot bileşiklerinin yüksek oranlara çıktığı anlaşılmaktadır (Şaşa, 2021).

2.3.5 Ozon (O₃)

Reaktif bir gaz olan ozon, yaklaşık % 90 oranında atmosferde troposfer ve stratosfer tabakalarında bulunan ve güneş ışığı varlığında oluşan ikincil bir kirleticidir. Stratosfer tabakasının üst katmanlarında bulunan stratosferik ozon/iyi ozon, güneşten gelen zararlı ultraviyole ışınları tutarak canlıları korur. Troposferde, antropojenik kaynaklardan oluşan ve ozonun öncül kirleticileri olan uçucu organik bileşikler ve azot oksitlerin güneş ışığının etkisiyle kimyasal reaksiyona girmesi neticesi oluşan troposferik ozon/kötü ozon, yer seviyesi ozon kirliliğine yol açmaktadır (Sağlar, 2019; Altıntaş, 2020; URL 1). Yer seviyesi ozon, şehrin üzerinde tabaka halinde birikebilmekte hatta önemli mesafelere de taşınabilmektedir (Morcalı ve Akan, 2017; Sağlar, 2019).

2.3.6 Partikül Madde (PM)

Partikül madde (PM); volkanik püskürmeler, sismik faaliyetler ve orman yangınları gibi doğal ve insan kaynaklı yanma türleri ve bazı endüstriyel faaliyetlerden olan antropojenik kaynaklardan gelmektedir. Hava kalitesini olumsuz etkileyen en önemli hava kirleticileri arasında yer almaktadır (Selçuk, 2019). PM, havada asılı halde bulunan organik ve inorganik maddelerin katı veya sıvı karışımları olarak tanımlanmaktadır (Altıntaş, 2020; URL 1). Atmosferde standart koşullarda sıvı veya katı olarak bulunan PM 0.1 ila 100 mikron arasında değişen boyut veya çaplarda bulunur (Tel, 2019). Kütle ve bileşimi yönünden; aerodinamik çapı 2.5 μm 'den küçük ince partiküller ve aerodinamik çapı 2.5 μm 'den büyük kaba partiküller olmak üzere iki gruba ayrılır. Küçük partiküller; ikincil olarak oluşan aerosoller (gaz-partikül dönüşümü), yanma sonucunda oluşan partikülleri, yoğunlaşan organik ve metal buharlarını içerir. Büyük partiküller; genelde yer kabuğu materyalleri yol ve endüstrilerden oluşan kaçak tozları içerir (Nuhoglu, 2014; Kırmacı, 2019). Ayrıca aerodinamik çapı 2.5 μm 'den küçük olanlar PM_{2.5}, 10 μm 'den küçük olanlar ise PM₁₀ olarak adlandırılır (Mangır, 2014). Partikül boyutları, PM'nin atmosferde kalma süresini belirleyen bir faktördür. PM₁₀'lar atmosferde birkaç saat içinde çökelme (sedimentasyon) gösterir ve yağışla beraber uzaklaşırken, PM_{2.5} atmosferde haftalarca kalabilir ve uzun mesafelere taşınabilir (Altıntaş, 2020).

Endüstriyel kaynaklardan gelen partikül madde emisyonları yılda 7,5 ton olarak belirlenmektedir ve orman yangınlarından kaynaklanan partikül madde emisyonu oranı toplam emisyonların % 25'idir (Ashoor, 2019; Sarı, 2019; Sağlar, 2019).

2.4 Kirleticilerin İnsan Sağlığına Etkileri

Birçok şehirde özellikle kış aylarında artan hava kirliliği insan sağlığı için bazı durumlarda ölümlere bile neden olan büyük bir problemdir. Son yıllarda dünya çapında toplu ölümlere neden olan bazı hava kirliliği olayları Çizelge 2.1'de verilmiştir.

Çizelge 2.1. Bazı hava kirliliği olayları ve sonuçları (Bıyık, 2010)

Tarih	Yer	Ölü Sayısı
Aralık 1930	Meuse Valley, Belçika	63
Ekim 1948	Donora, Pensilvanya	17
26 Kasım – Aralık 1948	Londra, İngiltere	700-800
5 – 9 Aralık 1952	Londra, İngiltere	4000
3 – 6 Ocak 1956	Londra, İngiltere	1000
2 – 5 Aralık 1967	Londra, İngiltere	700-800
26 – 31 Ocak 1959	Londra, İngiltere	200-250
5 – 10 Aralık 1967	Londra, İngiltere	700
7 – 22 Ocak 1963	Londra, İngiltere	200
9 – 12 Şubat 1963	New York, Amerika	200-400

Hava kirliliğinin insan sağlığına etkileri kirli havaya maruz kalınması sonucu fiziksel ve psikolojik olarak gözlenmektedir. Kirleticilerin cilde teması tahriş gibi çeşitli etkilere yol açmakta, bu durum kirleticilerin cins ve miktarı ile maruz kalınan süreye bağlı olarak değişkenlik göstermektedir. İnsan sağlığı üzerinde, üst solunum yolu tahrişinden maruz kalma oranına bağlı olarak, akut ve kronik etkilerin yanı sıra ölüm riskinin yüksek olmasına varan olumsuz etkileri bulunmaktadır. Hava kirliliği insanların yanı sıra bitki ve hayvanları da etkilemekte, hem ekolojik, hem de ekonomik anlamda ciddi sorunlara yol açmaktadır (Kırımhan, 2006; Menteşe, 2019).

Havada bulunan partikül madde, güneş ışığının yararlı etkilerini kısıtlayan, görüş mesafesini azaltan ve ekosistemde yaşayan tüm canlıların yaşamını tehdit eden etkilere neden olmaktadır. İnsan sağlığına olan etkilerinin başında ise kronik solunum yolu hastalıkları, solunum yetersizliği ve bronşit gibi hastalıklara neden olarak ölüm oranlarında etkili olduğu belirtilmektedir (Müezzinoğlu, 2000). PM_{10} ve $10\ \mu m$ boyutundan daha küçük PM'ler, insan ve diğer canlılar için zararlı etkiye sahip kirleticilerdir (Erdoğan, 2012). Yapılan bir araştırmada $PM_{2,5}$ konsantrasyonlarının astım, kronik obstrüktif akciğer hastalığı (KOAH) ve akciğer kanseri gibi hastalıklara yol açabileceği belirtilmiştir (Pope ve Dockery, 2006; Selçuk, 2019).

Havada bulunan karbon monoksit, kandaki vücut hücrelerinin oksijen taşıma kabiliyetini azaltarak insan sağlığına olumsuz etkilemekte ve ölümlere bile yol açabilmektedir (İncecik, 1994). Karbon monoksitin hemoglobine afinitesi, oksijenden 240 kat daha yüksek olduğundan kandaki hemoglobin ile birleşerek karboksihemoglobin oluşturmakta ve oksijenin hücrelere transferini önleyerek, kandaki oksijen seviyesinin azalmasına bağlı olarak insanda baş ağrısı, solunum yolu hastalıkları, yorgunluk, zehirlenme ve ölümlere neden olmaktadır (Erdoğan, 2012; Abayomi, 2017; Tel, 2019).

SO₂ yüksek konsantrasyonlarda öldürücü etkileri olan bir gazdır. Bu gaza uzun süre maruz kalmak, solunum bozukluklarına, akciğer fonksiyonu üzerinde olumsuz etkilere, bitkilerde hasara ve metal yüzeylerin aşınmasına neden olur, yapı malzemeleri, bitkileri ve ormanları asit yağışlarıyla tahrip eder. Noktasal kaynak olan bacalar bu gazın yaklaşık % 80'ini üretir ve havaya verir. 1952'de Londra'da hava kirliliği nedeniyle binlerce kişi ölmüştür (Bıyık, 2010; Tel, 2019).

NO_x'lerden olan NO₂, hava kalitesi ve insan sağlığı için önemli olan zehirli gazlardan biridir. NO'nun bir dizi toksik kirleticinin öncüsü olması ve NO₂ konsantrasyonlarına hem akut, hem de kronik maruziyet sonucu oluşabilecek etkileri nedeniyle atmosferik NO₂ konsantrasyonlarının düşük seviyelerde tutulmasının önemli halk sağlığı yararları sağlayacağı belirtilmektedir (Özcan, 2012). NO₂ kirliliğine yüksek konsantrasyonlarda maruz kalınması gözlerde tahriş, astım, bronşiyal semptomlar, akciğer fonksiyonlarında azalma, irritasyon ve kanamalara neden olmaktadır (Müezzinoğlu, 2000; URL 1).

Zararlı bir kirleticisi olan yer seviyesindeki ozon, özellikle güneşli havalarda ve yüksek sıcaklıkta oluşmaktadır (Gümüş, 2019). Ozon içeren havanın solunması; astım ve akciğer semptomlarında artış gibi solunum yolu ve kardiyovasküler rahatsızlıklara, baş ağrısı, bilinç kaybı ve boğazda kuruma gibi etkilere neden olarak, yüksek risk grubundaki kişilerin (astımlı insanlar, çocuklar, yaşlı yetişkinler ve açık havada aktif olanlar gibi) sağlığına önemli derecede zarar verebilir. Ozon; bronşit, amfizem ve astımı daha da kötüleştirerek tıbbi bakımın artmasına neden olabilir (Müezzinoğlu, 2000; EPA, 2019).

Kirli hava insanların bağımsıklık sistemine etki ederek birçok hastalığa yol açmaktadır. Çizelge 2.2’ de kirletici parametreler ve sağılık etkileri verilmiştir.

Çizelge 2.2. Kirletici parametreler ve sağılık etkileri (URL 2)

Kirletici	Ana Kaynağı	Sağılık Etkisi
PM	Her türlü yakma ve yanma işleri, tarımsal faaliyetler, ikincil kimyasal tepkimeler	Kanser, kalp problemleri, solunum yolu hastalıkları, bebek ölüm oranlarında artış
CO	Yakıtların tam yanma olmadan hava ortamına atılması, taşıt emisyonları	Kandaki hemoglobin ile birleşerek oksijen taşıma kapasitesinde azalma, ölüm
SO ₂	Fosil yakıtların uygun olmayan şekilde yakılması ve yanması	Akciğer yetmezliği, damar sertliği ve solunum yolu hastalıkları
NO _x	Yakma prosesleri ve moturlu araç ve gereçler	Akut solunum yolu hastalıkları, göz ve kalp hastalıkları, asit yağmurları
O ₃	Trafikten kaynaklanan azot oksitler ve uçucu organik bileşiklerin (VOC) güneş ışığıyla değişimi	Solunum problemleri, göz ve burun problemleri, astım, vücut direncinde azalma

2.5 Hava Kirliliğini Etkileyen Faktörler

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

2.5.1 Meteorolojik faktörler

Meteorolojik koşullar kirleticilerin taşınmasına neden olarak, atmosferde kirli ve temiz havanın birbirine karışmasına yol açar. Hava kirliliğini etkileyen başlıca faktörler sıcaklık, basınç, yağış, rüzgâr, nem ve atmosferik şartlardır (Sağlar, 2019).

Sıcaklık

Hava kütlesi içerisinde, ısı enerjisinin sonucu olan moleköl titreşimlerinin etrafa yaptığı etki olarak tanımlanmaktadır (Kırmacı, 2019; Sağlar, 2019). Kış aylarında hava sıcaklığının düşmesi yakıt tüketimini artırmakta, bunun sonucu havaya verilen kirleticiler de artmaktadır (Sağlar, 2019).

Rüzgar

Dünya yüzeyine yakın atmosfer içerisinde olan alçak basınçla yüksek basınç bölgesi arasında yer değiştiren hava akımına rüzgar denir. Rüzgarın yönü, hızı ve sıklığı belirleyici özellikleri olup, kirlenmiş havayı ortamdaki uzaklaştırmakta veya kirletilmiş havayı temiz ortamlara taşıyarak hava kirliliğine yol açmaktadır (Sağlar, 2019).

Yağış

Atmosferdeki su buharının çeşitli koşullarda yoğunlaşarak sıvı veya katı durumda yere düşmesine yağış adı verilir. Yağış ile birlikte kirli havadaki kirleticiler toprağa karışarak, yer değiştirmiş olur (Sağlar, 2019).

Basınç

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

Hava basıncı, yeryüzündeki havanın hareketli veya hareketsiz olmasını etkilemektedir. Alçak basınç alanlarında yükseltici hava hareketlerinden dolayı alt katlardaki kirli hava yukarılara çıkarak dağılmaktadır. Yüksek basınç alanlarında ise sübsidans (konveksiyonel hava hareketlerinden yukarıdan aşağıya doğru olan) söz konusu olduğu için aşağıdaki kirli hava yükselmemektedir (Sağlar, 2019; Şaşa, 2021).

Nem

Atmosferde bulunan su miktarı atmosferin nemliliği olarak adlandırılır (Kırmacı, 2019). Artan nem bazı kirletici konsantrasyonlarını artırırken bazı kirletici konsantrasyonlarının bir miktar azalmasında etkili olur (Kunt ve Dursun, 2018).

Güneş radyasyonu

Güneşten gelen ışınlar, atmosfere girdiğinde kırılıp, yansıyor, yutulur, yön ve şekil değiştirirler. Güneşten doğrudan gelen ve yayılan ışınların tümüne **global solar radyasyon** denir (Kırmacı, 2019).

2.5.2 Atmosferik şartlar (inversiyon)

Gerçek sıcaklık profilinin, termodinamik nedenlerle yükseklikle azalması gerekirken artmasına inversiyon denir. Rüzgar olmadığı durumlarda kararlılık çok yüksek olduğundan ve kirleticiler dağılma imkanı bulamadığı için hava kirlenmesi açısından olumsuz koşullar ortaya çıkmaktadır.

2.5.3 Topoğrafik faktörler

Topoğrafya, meteorolojik parametrelere ve dolaylı olarak kirlilik dağılımına etki etmektedir. Topoğrafik özellikler, hava akımının engellenmesine, dikey ve yatay yönde hava hareketlerinin oluşmasına neden olmakta ve yerleşim birimi üzerinde kirli hava kütesinin kalış süresini etkilemektedir (Sağlar, 2019).

2.5.4 Kentleşme

Hızlı kentleşme, nüfus artışı veya büyük kentlere göçler nedeniyle çeşitli çevre sorunları ortaya çıkmaktadır. Tarım alanlarının yok edilmesi, kentlerde konut sayısının artması, fazla taşıt sayısı ve buna bağlı yakıt tüketiminin artması sonucu hava kirliliği artmaktadır. Kış aylarında ısınmada kullanılan kalitesiz yakıtlar, uygun olmayan yakma

işlemleri ve düzenli kazan bakımının yapılmaması nedeniyle ısınmadan kaynaklanan hava kirliliği oluşmaktadır (Sağlar, 2019; Şaşa, 2021).

2.5.5 Sanayileşme

Önemli kirleticilerden biri olan sanayi tesislerinde hem kullanılan fosil yakıtlar hem de üretim sebebiyle atmosfere kirleticiler salınmaktadır. Sanayileşme ile birlikte atmosfere emisyon salımı gerçekleşmektedir. Sanayileşme de sanayi kuruluşlarının yanlış yerlerde yapılandırılması ve yanma sonucu oluşan atık gazların yeterli teknik önlemler alınmadan havaya bırakılması hava kirliliğine yol açmaktadır (Sağlar, 2019).

2.5.6 Sosyo-ekonomik yapı

Hava kirliliği ile sosyo-ekonomi arasında yakın ve karşılıklı bir ilişki bulunmaktadır. Ekonomik gelişmenin sürdürülmesi hava kirliliği artışına neden olurken, hava kirliliği de ekonomik gelişme ve yapı üzerinde etkili olmaktadır. Ekonomik gelişme hava kirliliğini, hava kirliliği ise ekonomik gelişmenin ekonomik ve sosyal maliyetini arttırmaktadır (Sağlar, 2019; Şaşa, 2021).

2.6 Kirleticilerin Atmosferde Hareketleri


Farklı kaynaklardan yayılan hava kirleticileri, meteorolojik koşullara bağlı olarak taşınır, yayılır veya bir bölgede toplanır. Taşınma sırasında kirleticiler seyrelir veya güneş ışığının etkisiyle kimyasal reaksiyonlara girer (Mayer, 1999; Nuhoğlu, 2014). Bu döngü, atmosferdeki kirleticilerin yağmurla yıkanarak, yüzeysel sulara, toprağa, bitkilere ve diğer malzemelerin üzerine çökmesi ile veya çeşitli etkenler sonucu ortamdan uzaklaşması ile tamamlanır. Kirleticiler bazı durumlarda rüzgâr nedeniyle atmosfere tekrar girebilir. Kirleticiler atmosferik hareketleri dikey ve yatay yönde hareketler olarak iki şekilde sınıflandırılabilir (Nuhoğlu, 2014).

Dikey Hareketler: Meteorolojik ölçeklerine bakılmaksızın, atmosferik hareketler, kirleticilerin atmosfere dikey taşınmasını sağlar veya engeller. Bu nedenle düşük basınç koşulları, yüksek basınç, atmosferik durgunluk ve atmosferik stabilite gibi önemli

konulardan bahsedilebilir. Salınan kirleticilerin atmosfere dağılmasını sağlamak için önce atmosferin kararlılığı bilinmelidir. Atmosferik stabilite, dikey karıştırma ve yatay hareket derecesinin bir ölçüsüdür. Atmosfer stabil ise kaynaktan salınan kirleticiler dünya yüzeyine yakın bölgede kalacak ve dağılmayacaktır. Sıcaklık değişim oranı parametrenin kararlılığına bağlıdır ve atmosferin kararlılığı doğrudan dikey sıcaklık özelliklerine bağlıdır. Bu sıcaklık özelliklerine göre, atmosferik stabilite genellikle kararlı, kararsız, enversiyon ve nötr olmak üzere dört şekildedir (Bıyık, 2010; Nuhuğlu, 2014).

Alçak Basınç (Siklon hareketi) : Soğuk hava kütesinin altına sıcak hava kütesinin girmesiyle oluşur. Oluşan sıcaklık farkı nedeniyle altta kalan sıcak hava kütesi yükselme eğilimi gösterir. Sıcak hava kütesi yükselirken düşük irtifalarda yerini çevresinden gelen hava doldurur. Oluşan bu içeri doğru hareket, yakınsayan siklonik bir harekettir ve spiral şeklinde yukarı doğru oluşur (Şekil 2.1).


Bu spiralin yönü güney yarım kürede saat yönünde, kuzey yarımkürede ise saat yönünün tersine gerçekleşir. Oluşan yukarı doğru hareket, alt atmosferdeki kirleticileri yukarı doğru taşıyarak dağıtır. Bu nedenle, alçak basınç sistemi kirleticilerin dağıtılması açısından istenen bir durumdur (Bıyık, 2010; Nuhuğlu, 2014).



Şekil 2.1. Kuzey yarım kürede bir siklonda yakınsayan rüzgarların düşük irtifa saat yönü tersindeki spiralleri

Yüksek Basınç (Antisiklon hareketi) : Alçak basınç durumunun aksine, yüksek basınç koşulları, bir soğuk hava kütesi bir sıcak hava kütesinin üzerine çıktığında oluşur. Soğuk hava kütedi aşağı doğru hareket etme eğilimindedir ve alçalırken yerini çevresinden gelen hava doldurur. Bu durumda oluşan aşağı doğru hareket dışı doğru spiral şeklinde olup, bu hava hareketine antisiklon hareketi de denilmektedir (Şekil 2.2). Hareket aşağı doğru olduğu için, yüksek basınç sisteminin bulunduğu bir bölgede

atmosfere salınan kirleticiler yukarı doğru hareket edemediğinden, hava kirliliği açısından istenemeyen bir durumdur (Bıyık, 2010; Nuhoğlu, 2014).



Şekil 2.2. Kuzey yarım kürede bir antisiklondan uzaksayan rüzgarların saat yönündeki spiralleri

2.7 Hava Kalite İndeksi ve Hesaplanması

Hava kalite indeksi (HKİ), hava kalitesini basit ve anlaşılabilir bir şekilde açıklayan, hava kirliliğine bağlı sağlık riski düzeyini ifade etmek için kullanılan bir terimdir (Karakuş ve Yıldız, 2019). HKİ, hava kalitesinin ölçüldüğü yerlerde; havanın kalite olarak iyi, orta, sağlıklı, kötü veya zararlı olduğu hakkında bilgi veren, günlük hava kalitesini raporlamak için kullanılan basit bir yoldur. HKİ, farklı hava kalitesi ile birlikte genel halk sağlığı üzerine etkisini, hava kirliliği seviyesinin sağlıklı seviyeye yükselmesi durumunda alınması gereken kademeleri belirleyerek, sağlığımızı hava kirliliğinden nasıl koruyacağımız konusunda bizlere yardımcı olur (Bıyık, 2010).

HKİ, kirleticilerin farklı konsantrasyon ve sürelerde insan sağlığına ilişkin farklı etkiler oluşturmaları göz önüne alınarak, hava kalitesi seviyesi veya hava kirliliği seviyesinin bir göstergesi olarak ifade edilen ve sayısal ölçekte düzgün bir şekilde rapor vermek için kullanılan kantitatif bir ölçüdür. Bu ölçekler renkle görselleştirildiğinde insanların büyük çoğunluğu tarafından anlaşılmakta, kişiler hava kirliliği düzeyinden ve oluşabilecek sağlık sorunlarından kolay bir şekilde haberdar olabilmektedir. Hava kalitesi indeksi; CO, NO₂, PM₁₀, SO₂ ve O₃ olmak üzere beş kirletici için hesaplanmaktadır (Tel, 2019; Karakuş ve Yıldız, 2019).

Hava kalitesi ölçümleri günlük yapılmalıdır. Ölçülen hava kirleticisi değerleri EPA tarafından geliştirilen standart formül kullanılarak HKİ değerlerine dönüştürülür. HKİ

değeri, her bir kirletici için ayrı ayrı hesaplanır ve kirleticilerden en yüksek HKİ'ne sahip değer o günün kirleticisidir. Sonuç olarak HKİ en kirli gazın indeks değerine eşit olmaktadır (URL 2).

Birçok ülkede kabul gören EPA HKİ (Çizelge 2.3), 0-500 arasında değişebilen bir ölçeğe sahiptir. Amaç; kirlilik konsantrasyonunu 0 ile 500 arasında bir sayıya dönüştürmektir. 0, 50, 100, 150, ...,500 arasındaki HKİ değerleri “kesme (kırılma) noktaları” olarak adlandırılır. Her bir HKİ kesme noktası, tanımlanmış bir kirlilik konsantrasyonuna karşılık gelir. HKİ, Çizelge 2.4' deki kesme noktaları ve denklem (2.1) ile hesaplanabilmektedir (Fang ve diğ., 2015; URL 2).

$$HKİ = \left[(I_{hi} - I_{low}) / (BP_{hi} - BP_{low}) \right] * (C_p - BP_{low}) + I_{low}$$

$$Nihai\ HKİ = \max (HKİ_1, HKİ_2, HKİ_3, \dots, HKİ_n)$$
(2.1)

Burada;

HKİ=Hava Kalite İndeksi,

C_p: Kirletici Konsantrasyonu,

BP_{hi}: Kirletici konsantrasyonundan daha büyük veya kirletici konsantrasyonuna eşit kırılma noktası,

BP_{low}: Kirletici konsantrasyonundan küçük veya kirletici konsantrasyonuna eşit kırılma noktası,

I_{hi}: BP_{hi}'ye karşılık gelen HKİ,

I_{low}: BP_{low}'a karşılık gelen HKİ'dir.

Çizelge 2.3. EPA HKİ (URL 2)

HKİ (AQI) Değer Aralıkları	Sağlık Endişe Seviyeleri	Renkler	Anlamı
0-50	İyi	Yeşil	Hava kalitesi memnun edici ve hava kirliliği az riskli veya hiç risk teşkil etmiyor.
51-100	Orta	Sarı	Hava kalitesi uygun fakat alışılmadık şekilde hava kirliliğine hassas olan çok az sayıdaki insanlar için bazı kirleticiler açısından orta düzeyde sağlık endişesi oluşabilir.
101-150	Hassas	Turuncu	Hassas gruplar için sağlık etkileri oluşabilir. Genel olarak kamunun etkilenmesi olası değildir.
151-200	Sağlıksız	Kırmızı	Herkes sağlık etkileri yaşamaya başlayabilir, hassas gruplar için ciddi sağlık etkileri söz konusu olabilir.
201-300	Kötü	Mor	Sağlık açısından acil durum oluşturabilir. Nüfusun tamamının etkilenme olasılığı yüksektir.
301-500	Tehlikeli	Kahverengi	Sağlık alarmı: herkes ciddi sağlık etkileri ile karşılaşabilir.

Çizelge 2.4. Ulusal Hava Kalitesi Değerleri Kesme (Kırılma) Noktaları (URL 2)

İndeks	HKİ	SO ₂ (µg/m ³)	NO ₂ (µg/m ³)	CO (µg/m ³)	O ₃ (µg/m ³)	PM ₁₀ (µg/m ³)
		1 sa. Ort	1 sa. Ort.	8 sa. Ort.	8 sa. Ort.	24 sa. Ort.
İyi	0-50	0-100	0-100	0-5500	0-120	0-50
Orta	51-100	101-250	101-200	5501-10000	121-160	51-100
Hassas	101-150	251-500	201-500	10001-16000	161-180	101-260
Sağlıksız	151-200	501-850	501-1000	16001-24000	181-240	261-400
Kötü	201-300	851-1100	1001-2000	24001-32000	241-700	401-520
Tehlikeli	301-500	>1101	>2001	>32001	>701	>521

2.8 Hava Kalitesi Standartları

Hava kalitesi düzenli bir şekilde ölçüldüğünde, kirliliğin ne düzeyde olduğu belirlenebilmekte, temiz hava planları çıkarılmakta, hava kirliliği haritaları oluşturulmakta ve dağılım modellemeleri yapılabilmektedir. Bu bağlamda oluşturulan hava kalitesi ölçümleri ile elde edilen sonuçlardan yola çıkarak, hava kalitesinin iyileştirilmesi bakımından çözüm önerileri sunulmakta ve standartlar daha sağlıklı, gerçekçi ve kolay bir şekilde uygulanabilmektedir. Bir bölgenin hava kalitesi belirlenirken; özellikle halkın, bitkilerin, ağaçların, hayvanların, taşıtların, yapıların ve malzemelerin hava kirlenmesine maruz kaldığı yerler seçilmeli, ölçüm istasyonları 1 saat, 8 saat, 24 saat ve yıllık periyotlar için yeterli sayıda veri üretebilmelidir. Hava kalitesi ölçüm çalışmalarında, topoğrafik ve meteorolojik faktörlerin bölgenin hava kalitesi seviyesi üzerine etkileri de belirlenmelidir (Sağlar, 2019). Çizelge 2.5'te hava kalitesi parametrelerinin sınır değerleri verilmiştir.

Hava kalitesi ölçüm ve izlemede; pasif örnekleyiciler, aktif örnekleyiciler, otomatik analizörler ve uzaktan algılayıcılar gibi metotlar kullanılmaktadır (Akcan ve Yeşilyurt, 2001).

Hava kalitesi standartlarının amacı, faaliyetler sonucu atmosfere yayılan kirlleticileri kontrol altına alarak, canlı yaşamına olumsuz ve zararlı etkilerini engellemektedir (Tel,

2019). Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği'nin amacı; hava kirliliğinin çevre ve insan sağlığı üzerindeki zararlı etkilerini önlemek veya azaltmak için hava kalitesi hedeflerini tanımlamak ve oluşturmak, tanımlanmış metotları ve kriterleri esas alarak hava kalitesini değerlendirmek, hava kalitesinin iyi olduğu yerlerde mevcut durumu korumak ve diğer durumlarda iyileştirmek, hava kalitesi ile ilgili yeterli bilgi toplamak ve uyarı eşikleri aracılığı ile halkın bilgilendirilmesini sağlamaktır (URL 3).

Çizelge 2.5. Hava kalitesi parametrelerinin sınır değerleri (URL1; URL2)

Parametre	SO ₂	NO ₂	CO [µg/m ³]	O ₃	PM ₁₀
	[µg/m ³]	[µg/m ³]		[µg/m ³]	[µg/m ³]
	1 Sa. Ort.	1 Sa. Ort.	8 Sa. Ort.	8 Sa. Ort.	24 Sa. Ort.
AB Üye Ülkeleri	350	200	10.000	120	50
Sınır Değeri					
Dünya Sağlık	10 Dakika:				
Örgütü Sınır	500	200	10.000	100	50
Değerleri (WHO)	Yıl: 20				

2.9 Literatür Araştırması

Torabi (2016) tarafından yapılan çalışmada, 22 ilçeye sahip Kabil şehri 1030 km² alana sahip olup, mevcut araştırma için 4. bölgenin ana yollarının hava kirliliği konsantrasyonu bir vaka çalışması olarak seçilmiştir. 4. bölge, 11.6 km² alana sahip olan şehrin kuzey tarafında yer almaktadır. Bu bölgedeki ana yollar iyi durumda değildir, çoğu asfaltsızdır, trafik geçişinde ve rüzgar eserken çok fazla kirlilik yaratmaktadır. Hava kalitesi izleme istasyonu 4. bölgede (34 ° 32'35.19 "K- 69 ° 8'19.29" D) yer almaktadır. Kabil, aşırı kalabalık ve düşük hava kalitesinden muzdarip, dünyanın en hızlı büyüyen şehirlerinden biridir ve son zamanlarda dünyanın en kirli şehirlerinden biri olarak bilinmektedir. Halk Sağlığı Bakanlığı'nın yaptığı epidemiyolojik araştırmalara göre Kabil'de hava kirliliğinin neden olduğu damar, kalp damar ve solunum hastalıkları ölüm oranını yüzde 4 artırmıştır. Bu nüfusu Kabil nüfusu ile karşılaştırdığımızda, hava kirliliği nedeniyle Kabil'de her yıl 3.000 kişinin öldüğü

söylenbilir. Hava kalitesi ile ilgili raporlara göre, havayı kirleten kirletici maddelerin salınması nedeniyle sonbaharın sonları ve kış aylarında hava kirliliği yüksek olup, Kabil'de insanlar evlerini ısıtmak için elektrik ve odun sıkıntısı çekmektedir. Bu nedenle bu aylarda şehirdeki hava kirliliğini artıran kömür, plastik vb. yakıtlar kullanılmaktadır.

Özçomak (2016) tarafından yapılan çalışmada, farklı emisyon sektörlerinin İzmir üzerindeki hava kalitesi üzerindeki etkisini ölçmek için EPA'nın Model3 çerçevesi kullanılmıştır. İlk aşamada kalite düzeyini belirlemek için İzmir ili analiz edilmiştir. Bu araştırmada İzmir'de sekiz istasyondan partikül madde ve kükürt dioksit ölçümü incelenmiştir. Hava kalitesi istasyon verileri incelendiğinde veri setine zaman serisi analizi, hiyerarşik küme analizi ve kutu diyagram analizi olan keşifsel veri analizi yöntemi uygulanmıştır. Bu aşamada basınç, sıcaklık, rüzgar yönü ve rüzgar hızı için meteorolojik analizler yapılmış, bu bölümde emisyon envanteri ve emisyon envanteri kullanımı hesaplanmıştır.

Deters vd. (2017) tarafından makine öğrenmesi ve seçilen meteorolojik parametreler kullanılarak $PM_{2.5}$ kentsel kirlilik modellemesinin yapıldığı çalışmada, $PM_{2.5}$ konsantrasyonlarını tahmin etmek için rüzgar (hız ve yön) ve yağış miktarlarının altı yıllık meteorolojik ve kirlilik veri analizlerine dayanan bir makine öğrenme yaklaşımı önerilmiştir. Sınıflandırma modelinin sonuçları, $PM_{2.5}$ konsantrasyonlarının düşük ($<10 \mu g/m^3$) ile yüksek ($>25 \mu g/m^3$) ve düşük ($<10 \mu g/m^3$) ile orta ($10-25 \mu g/m^3$) seviyede yüksek güvenilirlik gösterdiğini bulmuştur. $PM_{2.5}$ 'in regresyon analizi, iklim koşulları ekstrem hale geldiğinde (kuvvetli rüzgarlar veya yüksek yağış seviyeleri) $PM_{2.5}$ 'in daha iyi tahmin edildiğini göstermiştir.

Wang vd. (2017) tarafından yapılan iki aşamalı ayırıştırma tekniğine ve modifiye edilmiş aşırı öğrenme makinesine dayalı hava kalitesi indeksi tahmini için yeni bir hibrit model geliştirilen çalışmada, Pekin ve Şanghay'dan toplanan iki günlük hava kalitesi indeksi serisi ampirik çalışmada kullanılmıştır. Deneysel sonuçlar, iki aşamalı ayırıştırma tekniğine dayanan önerilen hibrit modelin, daha yüksek tahmin doğruluğu için dikkate alınan diğer tüm modellerden oldukça üstün olduğunu göstermiştir.

Ashoor (2019) tarafından yapılan çalışmada, Kabil'daki NEPA binasında bulunan hava kalitesi ölçüm istasyonunda yapılan ölçümler ile elde edilen hava kirliliği verileri

kullanılmıştır. Kabil kent merkezinde Nisan 2015-Nisan 2016 ayları arasındaki günlük ortalama SO₂, PM₁₀, NO₂, CO ve O₃ konsantrasyonları ve nem, sıcaklık, basınç, rüzgâr hızı verileri kullanılarak istatistiksel bir değerlendirme yapılmıştır. Kirlilik konsantrasyonları bağımlı değişkenler, meteorolojik parametreler ise bağımsız değişkenler olarak ele alınıp, mevcut bir yazılımın (EXCEL) kullanılması ile regresyon analizi yapılmıştır. Böylece Kabil kent merkezinde bir yıllık örnek bir sezonda meteorolojik koşulların hava kirliliğini hangi düzeyde ve nasıl etkilediği incelenmiştir.

Irmak ve Aydılek (2019) tarafından kullanılan veri seti, Adana ilinin valilik istasyonuna ait 2013-2017 yılları arasındaki PM₁₀, SO₂, NO₂, O₃ ve CO hava kirleticilerinin saatlik ölçüm değerlerinden oluşmaktadır. Veri seti ilgili bakanlığa ait internet adresinden elde edilmiştir. Deneysel çalışmada; SO₂ ve NO₂ gazlarının saatlik ortalama değerleri, CO ve O₃ gazlarının son 8 saatlik ortalama değerleri ve PM₁₀ toz değerinin son 24 saatlik ortalama değerleri hesaplanarak kullanılmıştır.

Ayturan (2019) tarafından yapılan çalışmada gelecekteki PM_{2,5} konsantrasyonlarını daha yüksek doğruluk oranları ile tahmin etmek için derin öğrenme yöntemi kullanılmıştır. Geçmiş yıllara ait PM konsantrasyon verileri, meteorolojik faktörler, havadaki diğer kirleticilerin konsantrasyonları da dikkate alınarak tahmin kabiliyeti yüksek bir model oluşturulmuştur. derin öğrenme yöntemi kullanılmıştır. Veriler, Çevre ve Şehircilik Bakanlığı'nın hava kalitesi izleme istasyonlarından temin edilmiştir. Bu çalışmada makine öğrenmesinin alt sınıfı olan derin öğrenme algoritmaları kullanılmış ve özellikle geçitli tekrarlayan ünite (GTÜ) ve devirli sinir ağları (DSA) kombinasyonu ile kısa süreli tahmin performansı %83'e yakın bir model oluşturulmuştur.

Karakuş ve Yıldız (2019) tarafından yapılan çalışmada, Sivas kent merkezinde bulunan üç adet hava kalitesi izleme istasyonuna ait hava kirletici parametreleri kullanılarak çoklu regresyon yöntemi ile Hava Kalite İndeksi (HKİ) hesaplanmış ve hava kirliliği değerlendirilmiştir. EPA Hava Kalitesi İndeksi Sınıflandırması'na göre; Sivas kent merkezinde hava kirliliğinin HKİ açısından “İyi” ve “Orta” düzeyde olduğu tespit edilmiştir. Çoklu regresyon analizi kapsamında sıcaklık, rüzgâr hızı ve nem bağımsız değişken ve HKİ bir bağımlı değişken olarak kabul edilmiştir. Analiz sonucunda; sıcaklık, rüzgâr hızı ve nem ile HKİ arasında anlamlı bir ilişki olduğu ortaya çıkmıştır. I, II ve III no'lu istasyonlar için hesaplanmış olan R² değerleri sırasıyla 0.15, 0.62 ve

0.48 olarak belirlenmiştir. Çoklu doğrusal regresyon analizi ile elde edilen sonuçlara göre, II no'lu istasyon (Başöğretmen) için R^2 değeri 0.62 olarak belirlenmiş, bu istasyonda HKİ ile meteorolojik parametreler arasında orta düzeyde anlamlı ($p<0,05$) bir ilişki olduğu sonucuna varılmıştır.

Ma vd. (2019), hava kalitesinin tahmininde derin öğrenmeye dayalı bir yöntem kullanmış ve önerilen yöntemi test etmek için Çin'in Guangdong şehrinde bir vaka çalışması yapmıştır. Çerçevenin performansı, yaygın olarak görülen diğer makine öğrenme algoritmaları ile karşılaştırılmış ve sonuçlar, önerilen transfer edilen çift yönlü uzun kısa süreli bellek modelinin, özellikle daha büyük zamansal çözünürlükler için daha küçük hatalara sahip olduğunu göstermiştir.

Londra'da PM_{10} ve NO_x kullanarak bir $PM_{2.5}$ ölçüm veri tabanını geliştirmek için regresyon modelleme ve bir makine öğrenme yönteminin (Random Forest-RF) yanı sıra ikisinin bir kombinasyonunu kullanmanın metodolojisini ve sonuçlarını rapor eden Analitis vd. (2020) tarafından yapılan çalışmada, regresyon modeli ve radyo frekansına göre tahminlerin kombinasyonunun en iyi performansı gösterdiği bulunmuş ve 5 yıllık dönemler için sırasıyla 2004–2008 ve 2009–2013 için %99.29 ve %98.22 çapraz doğrulama R^2 elde edilmiştir.

Behal ve Singh (2020), makine öğrenmesi tekniklerini kullanarak benzen gibi hava kalitesi parametrelerini izlemek ve tahmin etmek için nesnelerin internetine dayalı otomatikleştirilmiş bir çerçeve önermiştir. Önerilen modeli doğrulamak için dört zorlu veri seti üzerinde çok sayıda deneysel simülasyon yapılmış ve sonuçlar birkaç modelle karşılaştırılmıştır. Karşılaştırmalı analiz, doğruluk (%97.3), belirleme katsayısı (%94.01) ve ortalama kare hatası (%2.4) açısından sunulan model için geliştirilmiş istatistiksel değerleri göstermiştir.

Choubin vd. (2020), İspanya'nın Barselona şehrinde PM_{10} 'un tehlike tahmini için Rastgele Orman, Torbalı Sınıflandırma ve Regresyon Ağaçları ve Karışım Ayrım Analizi gibi yeni makine öğrenmesi modelleri geliştirmeyi amaçlamıştır. Sonuçlara göre, üç makine öğrenmesi modelinin de mükemmel bir performans gösterdiği (Doğruluk > %87 ve hassasiyet > %86), ancak Torbalı Sınıflandırma ve Regresyon

Ağaçları ve Rastgele Orman modelleri, Karışım Ayrım Analizi modeliyle aynı ve daha yüksek performansa sahip olduğu görülmüştür.

Doreswamy vd. (2020), atmosferdeki partikül madde konsantrasyonunu tahmin etmek için makine öğrenmesi tahmin modelleri ile 2012'den 2017'ye kadar elde edilen Tayvan Hava Kalitesi İzleme veri setleri üzerinde yaptıkları çalışmada mevcut geleneksel modellerle karşılaştırıldığında PM tahmininde daha iyi performans gösterdiğini tespit etmişlerdir.

Yapay zeka yardımıyla koronavirüsün İtalyan bölgesel ve taşra nüfuslarını farklı şekilde etkilemesinin olası nedenlerinin incelendiği Cazzolla vd. (2020) tarafından yapılan çalışmada, çeşitli çevresel, sağlık ve sosyo-ekonomik faktörler arasında, ana bileşen olarak hava kirliliği ve ince partikül maddenin ($PM_{2.5}$), Şiddetli Akut Solunum Sendromu-CoV-2 etkilerinin en önemli belirleyicileri olduğu tespit edilmiştir. Hava kirliliğinin oynadığı büyük katkı göz önüne alındığında hava kirliliğinde %5-10'luk bir artışla, benzer gelecekteki patojenlerin İtalya'nın salgın seviyesini artırabileceği sonucuna varılmıştır.

Kumar vd. (2020), Delhi'nin çeşitli bölgelerindeki $PM_{2.5}$ konsantrasyon seviyelerini saatlik olarak tahmin etmesi için rüzgar hızı, atmosferik sıcaklık, basınç gibi çeşitli atmosferik ve yüzey faktörlerine dayalı olarak zaman serisi analizi ve regresyon uyguladığı çalışmada, analiz için gerekli olan verileri Hindistan Meteoroloji İstasyonu tarafından şehirde kurulan çeşitli hava durumu izleme alanlarından temin etmiş ve Extra-Trees regresyonunu ve AdaBoost'u kullanan bir regresyon modeli önermiştir. Delhi'nin 2016-2018 yılından itibaren 2 yıllık döneme tekabül eden çeşitli meteorolojik ve kirlenici parametrelerinin günlük $PM_{2.5}$ konsantrasyonlarını tahmin etmek için destek vektör makinesi ve yapay sinir ağı olmak üzere iki farklı model oluşturulmuştur. Bu simülasyon çalışmasının sonuçları, yapay sinir ağının $PM_{2.5}$ tahmini için destek vektör makinesinden daha iyi tahmin doğruluğu verdiğini göstermiştir.

Mao vd. (2021), Jing-Jin-Ji bölgesinde 24 saatlik ortalama $PM_{2.5}$ konsantrasyonunun hava kalitesini tahmin etmek için çoklu doğrusal regresyon, destek vektörü regresyonu, geleneksel uzun kısa süreli bellek ve uzun kısa süreli bellek genişletilmiş modellerle karşılaştırıldığında, yüksek korelasyon katsayısı R^2 (0,87) ile daha iyi stabilite ve performansla sonuçlandığını bulmuştur.

Wong vd. (2021) tarafından yapılan çalışmada, Tayvan'ın ana adasındaki Tayvan Çevre Koruma Ajansı'na ait 73 sabit hava kalitesi izleme istasyonundan günlük ortalama PM_{2.5} verileri toplanmıştır. PM_{2.5}'in mekansal-zamansal değişkenliğini değerlendirmek için makine öğrenmesi bir arazi kullanımı regresyon modeli kullanılmıştır. Analiz için 2006'dan 2016'ya kadar yaklaşık 280.000 gözlem kullanılmıştır. Ardından, arazi kullanımı regresyon modelleri tarafından seçilen değişkenlere dayalı tahmin modeline uymak için derin sinir ağı, rastgele orman ve XGBoost algoritmaları kullanılmıştır. Sonuçlar, önerilen geleneksel arazi kullanımı regresyonunun ve Hibrit Kriging arazi kullanımı regresyon modellerinin PM_{2.5} varyasyonlarının sırasıyla %58 ve %89'unu yakaladığını göstermiştir. XGBoost algoritması dahil edildiğinde, modellerin açıklama gücü sırasıyla %73 ve %94'e yükselmiştir. Bu çalışma, PM_{2.5} maruziyetlerinin uzamsal-zamansal değişkenliğini tahmin etmek için Hibrit Kriging-arazi kullanımı regresyon modeli ile bir XGBoost algoritmasını birleştirmenin gerekli olduğunu göstermiştir.

Zeng vd. (2021), Çin genelinde yaklaşık 2400 sahada yüksek yoğunluklu yer meteorolojik gözlemlerine dayanan LightGBM modelini kullanarak saatlik PM_{2.5} konsantrasyonundan oluşan sanal bir ağ kurarak bu boşluğu doldurmayı amaçlanmıştır. Sanal ağ, Çin genelinde 0.86 R², 14.99 µg/m³ ortalama karekök hata değerleri ve 9.48 µg/m³ ortalama mutlak hata (Çapraz Doğrulama sonuçları) ile Çin genelinde istenen bir saatlik PM_{2.5} tahmini performansını göstermiştir. Bu arada, tahmini PM_{2.5}'in doğruluğunu artırmak için makine öğrenmesi modelinde birincil tahmin edici olarak kullanılabileceği bulunmuştur.

2.10 Dünyada ve Kabil'de Hava Kirliliği

2.10.1 Dünya'da hava kirliliği


Hava kirliliği atmosferde bulunan partikül madde, azot oksitler, sülfür dioksit ve ozon gibi kirleticilerin insan ve diğer canlılara zarar verecek miktarlara kadar çıkmasıdır (Baş, 2019). Atmosferdeki doğal süreçleri bozan ve insan sağlığı üzerinde olumsuz etkiye sahip olan hava kirliliğinin son 30 yıldır düzenli olarak izlenmesine ve mücadele edilmesine rağmen, hala bu sorunlar büyük şehirlerde sınır değerlerin üzerinde bulunmaktadır. 80'li yıllara kadar dünyada hava kalite standartlarının üzerinde kirliliğe sahip şehirlerde yaşayan 1,3 milyar insan tespit edilmiştir. Hava kirliliğinin ana

kaynağı, konutlarda tüketilen yakıtlar ve motorlu araç egzozlarıdır. 2030 yılına kadar dünyadaki hava kirletici emisyonları özellikle gelişmekte olan şehirlerde hızlı kentleşme ve enerji tüketiminin artışı ile birlikte artmaktadır (Bayram, 2006).

Araştırmalar, göre hava kirliliğinin çocuklarda akut solunum yolu enfeksiyonu riskini arttırdığını, solunum kalp problemlerini artırmaya devam ettiğini ve daha fazla ölüme neden olduğunu göstermiştir. Hava kirliliği araştırmalarının çıkış noktası, 1934'te Belçika'da Meuse Vadisinde, 1947'de ABD'de Donora'da ve 1952'de Londra'da bir aydan kısa sürede binlerce kişinin ölümüyle sonuçlanan ve çok yüksek PM emisyonlarının atmosferik inversiyon olayları ve topografik yapıdan kaynaklanan hava kirliliği episodları olmuştur. Buna dayanarak, Londra'da kömür kullanımının sınırlandırıldığını belirten bir kontrol yöntemi uygulanmıştır. Kirleticilerin değerleri ve emisyonları Dünya Sağlık Örgütü tarafından belirlenmektedir (Bayram, 2006).

Dünya Sağlık Örgütü'nün küresel verilerden derlediği 2018 raporu, zengin ve fakir ülkeler arasında hava kirliliğinde eşitsizlik olduğuna dikkat çekmektedir. Raporda, 10 kişiden 9' unun kötü hava soluduğu belirtilmektedir. Rapor, kıta şehirlerinin % 57'sinde ve Avrupa şehirlerinin % 61'inde 2010'dan 2016'ya PM_{10} ve $PM_{2.5}$ oranlarında bir düşüş olduğunu göstermektedir (Şekil 2.3) (URL 4).


Şekil 2.3' den de görülebileceği gibi, hava kirliliği üzerinde en kötü etkiye sahip ülkeler Güney ve Güneydoğu Asya'dır. En yüksek partikül madde seviyelerine sahip en önemli kirli şehirler Dünya Sağlık Örgütü tarafından belirlendiği gibi Hindistan'ın Delhi ve Mısır'ın Kahire şehirleri olarak tanımlanmıştır (URL 4).



Şekil 2.3. Dünya’da ülkelerin gelir dağılımına göre 2010’dan 2016 yılına doğru hava kirliliği değişimi

İki farklı çalışma, yetersiz önlemlerin gelişmekte olan ülkelerde hızlı kentleşme ve artan enerji tüketimi nedeniyle hava kirliliğini artırdığını ve gelişmekte olan ülkelerde kirliliği azaltmak için uygun önlemleri alamadığını göstermektedir.

2020 yılında yapılan araştırmaya göre dünyanın en yüksek hava kirliliğine sahip olan ülkeleri; Bangladeş, Pakistan, Hindistan, Afganistan, Bahreyn, Moğolistan, Kuveyt, Nepal, Birleşik Arap Emirlikleri, Nijerya, Endonezya, Çin, Uganda, Bosna-Hersek ve Kuzey Makedonya'dır (URL 4). Şekil 2.4'te $PM_{2.5}$ konsantrasyonunun en yüksek olduğu ülkeler verilmiştir.



Şekil 2.4. PM2.5 konsantrasyonunun en yüksek olduğu ülkeler

2.10.2 Kabil'in hava kirliliği

Kabil ve diğer büyük Afgan şehirlerindeki hava kalitesi önemli ölçüde zayıfken, çoğu Afgan şehri banliyölerde kirletici bulunmaması nedeniyle iyi hava kalitesine sahiptir. Çok tehlikeli hava kirliliğinden muzdarip olan Kabil şehri, dünyanın en kirli şehirlerinden biri olarak kabul edilebilir. Halk Sağlığı Bakanlığı'nın epidemiyolojik çalışmalarına göre, Kabil'deki hava kirliliği nedeniyle kardiyovasküler ve solunum yolu hastalıkları ülkenin ham ölüm oranını % 4 artırmaktadır. Kabil'deki hava kirliliği nedeniyle her yıl yaklaşık 3.000 kişi daha hayatını kaybetmektedir (URL 5)

Asya Kalkınma Bankası'ndan teknik destek olarak Ulusal Çevre Koruma Ajansı, Kabil Hava Kalitesi Yönetim Projesi'ni üç proje altında hayata geçirmiştir. Proje (KAQM), Kabil için Afganistan'ın diğer bölgelerinde tekrarlanabilecek adım adım ve sürdürülebilir hava kalitesi ve yönetim planının geliştirilmesine ve önceliklendirilmesine yardımcı olmayı amaçlamaktadır. Bu amaçla, kirleticileri analiz etmek için ortalama 24 saat hava kalitesi numunesi toplamak amacıyla şehrin bazı bölgelerine sekiz hava kalitesi izleme istasyonu kurulmuştur. Bu istasyonlar, partikül madde, azot oksitler ve kükürt dioksitin atmosferik yüklerini belirlemek için kurulmuştur (URL 5).

Kabil’de, PM₁₀ emisyonunun toplam 17.363 tona ulaştığı tahmin edilebilmektedir. PM₁₀’un başlıca emisyon kaynakları, toz ve araç (%52), konut ısıtması için yakma (%31) ve tuğla fırınları (%12)’dir. NO_x ’in başlıca kaynakları portatif jeneratörler (%19), SO₂’nin ana kaynakları alan ısıtması (%15) , konut ısıtması (%8), jeneratörler (%8) oluşturmaktadır. Başlıca alan ısıtması (%39) ve CO emisyonları benzinli araçlarda (%36) teşkil etmektedir. Kabil’deki NO_x, PM₁₀ ve SO₂ ortam hava kalitesi seviyeleri, WHO ve USEPA kurallarını rutin olarak aşmaktadır. Nüfus maruziyeti genel popülasyondaki morbidite ve mortalite maliyetlerini değerlendirmek için hesaplanmıştır. Nüfusun yüzde 68’i 120 µg/m³ SO₂ konsantrasyonuna maruz kalmaktadır ve yüzde altmışı 1.500 µg/m³ PM₁₀’dan daha fazlasına maruz kalmaktadır (Ashoor, 2019).

İnsan sağlığı için ciddi bir tehdit oluşturan kütlelerin (bitki kalıntıları, saman, odun ve kömür) kullanıldığı iç mekan hava kirliliği, evlerde iç mekan havasını kirleten yüksek miktarlar üretmektedir. Asya’da yapılan araştırmalara göre, kömür yakıtı kullanan hanelerde iç mekan hava kirliliği oranı daha yüksektir. Örneğin, bir madde parçacığının dökme yakıt kullanan 24 saat içindeki ortalaması 1.000 µg/m³ ulaşmaktadır. Mevcut tüm sınırlamalara rağmen, Avrupa Birliği tarafından belirlenen partikül miktarı 50 µg/m³’dir. İç ortam hava kirliliği, 5 yaşın altındaki çocuklarda olumsuz sağlık sorunlarına neden olan pnömoninin en yaygın nedenidir. 30 yaşın üzerindeki yetişkinlerde ise, akciğer kanserinin özellikle evde olan kadınlarda koroner kalp hastalığı ile ilişkili olduğu tespit edilmiştir (URL 5).

Kabil’deki çeşitli kirleticiler konsantrasyonlarının tahminleri, toz, tuğla fırınlar, araçların, trafiği, konut ısıtma ve jeneratörler hava kirliliğinin başlıca kaynaklarıdır. Tahmini toplam yıllık emisyonlar, Çizelge 2.7’ de verilmektedir:

Çizelge 2.6. 2005 yılında Kabil'in toplam tahmini yıllık emisyonları

Kaynak	PM	NO_x	SO₂	CO	CO₂	TOC
Araçlar						
Benzinli Araçlar	310	1,700	113	34,450	-	-
Dizel Araçlar	1,387	9,475	1,625	9,615	-	-
Tekrar Süspansiyonu	7,278	-	-	-	-	-
Toplam Taşıt	8,976	11,175	1,739	44,065	-	-
Konut Kaynakları						
Konut/Ticari Isıtma	5,562	1,241	381	38,077	511,833	7,333
Konut/Ticari Jeneratörler	223	3,131	207	3,028	120,822	324
Fırınlr	463	44	7	3,492	-	736
Hamamlar	160	15	2	1,209	-	255
Toplam Konut Kaynakları	6,249	4,431	597	45,807	632,655	8,648
Endüstriyel Kaynaklar						
Termal elektrik santrali	35	347	110	32	-	16
Endüstriyel Jeneratörler	12	185	10	7,121	17,629	239
Tuğla Fırınları	2,030	44	25	44	30	0,19
Asfalt	62	2	3	0.10	532	0,64
Toplam Endüstriyel Kaynaklar	2,138	578	148	7,197	18,191	256

2.10.3 Kabil'in hava kirliliğinin kaynakları

Kabil'deki başlıca hava kirliliği kaynakları:

- Araçların trafiği, eski araçların kullanımı ve ziyan yakıtlar
- Tozun yeniden süspanse edilmesi, rüzgâr üflemeli toz, hasarlı yollar
- Kış aylarında yakıt olarak, kömür, odun, dizel ve hayvan kalıntısı yakılması
- Düzensiz güç kaynağı nedeniyle özel olarak kullanılan jeneratörlerin muazzam kullanımı
- Fırınlr ve kamu yıkama salonlarda yakıt olarak odun yakılması
- Tuğla Fırınları, hepsi eski moda ve maalesef konut alanlarda yer almaları
- Asfalt fabrikaları

- Termik santral ve küçük ebatlı endüstriler
- İnşaat faaliyetleri
- Taş kırma ve halı temizleme endüstrileri (Ashoor, 2019).

şeklinde sıralanabilir.

2.10.3.1 Nüfus artışı

Kabil, dört milyonluk nüfusu ile Afganistan'ın en kalabalık şehridir. 1999 yılında 1.78 milyon olduğu tahmin edilen şehrin nüfusu, 2016 yılında dört milyona (yüzde 15) yükselmiştir (Torabi ve Nogami, 2016).

Kabil şehrinin nüfus yoğunluğu şehrin banliyölerinden daha yüksektir. Sonuç olarak Kabil, benzer yoğunluklara sahip diğer Asya şehirlerinden daha az yoğunlaşmıştır. Kabil, Afganistan'daki bir eğitim, sanayi, yönetim, ticaret ve iletişim merkezidir. Şehir içinde ve çevresinde yeterli iş imkanı ve uzak bölgelerdeki temel hizmetlerin eksikliği insanların Kabil'e ve şehrin diğer bölgelerine taşınmasına neden olan sebeplerinden biri olarak tanımlanmaktadır. Kabil'deki hızlı nüfus artışı Kabil nüfusunun yüzde 80'inin kent bölgelerinin üçte ikisini kapsayan gayri resmi alanlarda yaşamasına neden olmuştur. Kabil'deki evlerin inşaatı, ulaşım sorunlarına, atık yönetimine, sanitasyona ve hava kirliliğine neden olacak şekilde planlanmamıştır (Torabi ve Nogami, 2016).

2.10.3.2 Sanayi faaliyetleri

Üretim ve işleme faaliyetleri sonucu bacalarda oluşan toz, emisyonlar ve sanayiden oluşan havayı kirliliği sanayi kaynaklı hava kirliliği olarak tanımlanmaktadır. Sanayi tesislerinde enerji ihtiyacı için kullanılmakta olan yakıtlar ve işletmelerde yapılan işlemde (asit vb. maddeler ile işlemler) kaynaklı hava kirliliği baca yolu ile havaya atılarak atmosferde kirliliğe neden olmaktadır (Ekinci, 2019).

Kabil, Afganistan'ın sanayi kentlerinden biridir. Bu şehir'de içecek, demir cevheri, ilaç sanayi vb. sanayi kuruluşları vardır. Tüm bu fabrikalar, bu sektörlerde kullanılan düşük kaliteli yakıtlar, plastikler ve diğer yakıtları kullanarak Kabil'in havasını kirletmiştir. İnsanların hasta olma sebeplerinden biri bu havadır. Çizelge 2.7'de Afganistan'daki aktif sanayi şirketlerinin sayısı verilmiştir.


Çizelge 2.7. Afganistan'daki aktif sanayi şirketlerinin sayısı (NEPA, 2012)

Sektör	1979	2005	2006	2007	2008	2009	2011
Kimyasallar	25	45	58	61	58	58	55
İnşaat malzemeleri	13	65	84	93	101	105	105
Makine ve metal işleme	17	54	78	86	78	80	75
İlaçlar	5	7	10	12	14	11	13
Baskı	24	47	56	60	63	63	70
Ticari ve kâğıt	6	43	47	50	45	37	32
Hafif endüstriler	47	31	49	57	64	66	66
Gıda endüstrisi	67	152	199	206	212	199	195
Diğer sektörler	1	123	161	183	196	192	195
Toplam	205	567	742	808	831	811	806

2.10.3.3 Trafik faaliyetleri

Ulaşımda kullanılan araçlar hayatımızda önemli bir yere sahiptir. Günlük hayatımızda yararlandığımız bu motorlu taşıtların havaya yaydığı atık gaz ve partiküller çevremizi ve soluduğumuz havayı kirletmektedir. Solunan havadaki kirliliğin yaklaşık yüzde ellisinin karayolu taşıtlarından kaynaklı emisyonlardan kaynaklandığı bilinmektedir. Bunun sonucunda büyük kentlerin topluma açık alanlarında havayı kirleten emisyonlar büyük yer teşkil etmektedir (Ekinci, 2019).

Kirleticilerin önemli bir kısmı, özellikle ülkedeki trafik kazalarına aittir. Kentsel çevre kirliliğine katkıda bulunan diğer faktörler arasında yakıt veya fosil yakıtlar (kaliteli hobiler), şehirlerde yıpranmış ve amortismanlı araçların çoğalması, dar ve alışılmadık yollar ve belirli sayıda araçla (Şekil 2.5) yol haritalarının bulunmaması yer alır. Nüfus yoğunluğu ve araç tonajı, ulusal otobüs kısıtlılığı veya toplu özel toplu taşıma (büyük hizmetler ve yüksek model) nedeniyle nüfus yoğunluğu ve yol bitüm kapasitesi ile orantılı trafik, kentsel yüksek ücret alanlarındaki otoparkların olmaması ve hızlı hareket eden otomobillerin satın alınmasıdır (Barak, 2019).



Şekil 2.5. Afganistan’da araç sayısı artışı (Agerskov, 2013)

2.10.3.4 Katı atık üretimi

Katı atık üretimi, türleri ve özellikleri Kabil’de dört mevsim değişmektedir. Birçok faktör söz konusudur ve bu güç, yoksul insanların yıl boyunca yakıt amacıyla atık yakarak kendilerini sert bir kışa hazırlamaları için bir tür kısıtlama yaratır ve bu da iklim ve çevresel değişikliklere yol açmaktadır. Çöp işleme, Kabil’de her zaman bir sorundur. Çöpler günlük olarak evlerden ve sokakların köşelerinde, son depolama alanına ya da başkentin dışındaki depolama alanına dökülmeden önce toplanmaktadır. Çöp ve toplama noktaları şehrin her yerinde çok plansız bir şekilde görülebilmektedir. Düzenli depolama, şehir merkezinden yaklaşık 16 ila 20 kilometre uzaklıktadır (Torabi ve Nogami, 2016).

BÖLÜM III

MAKİNE ÖĞRENMESİ ALGORİTMALARI

3.1 Makine Öğrenmesi Kavramı

Makine öğrenmesi, yapay zekanın önemli bir alt alanıdır. Temel amacı, veriden bilgi elde etmek için hesaplama yöntemlerini kullanmaktır. Makine öğrenmesi, karmaşık örüntü algılama ve veriye dayalı karar verebilme özellikleriyle ele alınan problemin çözümünü kendi kendine öğrenebilen bilgisayar algoritmalarının genel adıdır. Varolan veri setleri ve kullanılan makine öğrenmesi yöntemleri ile oluşturulan model, en yüksek performansı elde etmek üzerine kurulmaktadır (Gültepe, 2019).

Makine öğrenimi, bilgisayarların algılayıcı verisine dayalı öğrenimini olanaklı kılan veriler üzerinde tahmin yapabilen algoritmaların inşasını ve geliştirme süreçlerini konu edinen bir bilim dalıdır. Bu algoritmalar örnek veri ile beslenir ve bu veriye dayanarak bir model geliştirir. Bu algoritmalar sayesinde eldeki ham veri kullanılmadan önce bu verileri temsil eden daha anlamlı veriler çıkartılır (Şahin, 2018).

Makine öğrenmesi, el yazısı ve konuşma tanıma, robotik ve bilgisayar oyunları, doğal dil işleme, beyin-makine arayüzü vb. dahil geniş bir uygulama yelpazesine sahiptir. Çevre bilimlerinde, veri işleme, model emülasyonu, hava ve iklim tahmini, hava kalitesi tahmini ve hidrolojik tahminlerde makine öğrenmesi yöntemleri yoğun olarak kullanılmaktadır. Günümüz yapay zeka teknolojilerinden makine öğrenmesi ile hava kirliliğine yönelik objektif ve daha hassas sonuçlar elde edilmektedir (Gültepe, 2019).

Makine öğrenmesinde; denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme, takviyeli öğrenme ve pekiştirmeli öğrenme gibi yöntemler kullanılmaktadır (Şahin, 2018).

3.2 Makine Öğrenmesi Algoritmaları


3.2.1 Lineer regresyon

Regresyon analizi, bağımlı bir değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkilerin tahmin edilmesi için kullanılan istatistiksel yöntemdir. Değişkenler arasındaki ilişkinin gücünü değerlendirmek ve aralarındaki gelecekteki ilişkiyi modellemek için kullanılabilir. Regresyon analizi, doğrusal, çoklu doğrusal ve doğrusal olmayan gibi çeşitli varyasyonları içerir. En yaygın kullanılan modeller basit doğrusal ve çoklu doğrusaldır (Andrews, 1974).

Basit doğrusal regresyon, bir bağımlı değişken ile bir bağımsız değişken arasında ilişkilidir. Basit bir doğrusal regresyon modeli, ε 'nin bir hata olduğu Denklem 3.1 ile ifade edilebilir.

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (3.1)$$

Şekil 3.3' de görüldüğü gibi, basit doğrusal regresyon modelinin ilişkisi düz bir çizgi ile gösterilir. Bağımlı ve bağımsız değişkenin ilişkisi doğrusal ise, doğrusal regresyon formülü istatistiksel yöntemler kullanılarak bulunabilir (Sözer, 2018).



Şekil 3.1. Basit doğrusal regresyon grafiği

Çoklu doğrusal regresyon, basit doğrusal regresyondan farklı olarak iki ve daha fazla bağımsız değişken ve bir bağımlı değişken arasındaki doğrusal bağıntıyı inceler. Bir çoklu doğrusal regresyon veya çok değişkenli doğrusal regresyon modeli Denklem 3.2 ile ifade edilir, burada ε hata terimi, β_n regresyon katsayısı ve n gözlemleri temsil eder.

$$\begin{aligned} y_1 &= \beta_0 + \beta_1 x_{1,1} + \beta_2 x_{2,1} + \dots + \beta_n x_{n,1} + \varepsilon_1 \\ y_2 &= \beta_0 + \beta_1 x_{1,2} + \beta_2 x_{2,2} + \dots + \beta_n x_{n,2} + \varepsilon_2 \\ &\vdots \\ y_n &= \beta_0 + \beta_1 x_{1,n} + \beta_2 x_{2,n} + \dots + \beta_n x_{n,n} + \varepsilon_n \end{aligned} \quad (3.2)$$

β regresyon katsayısını hesaplamak için genellikle en küçük kareler yöntemi tercih edilmektedir. Regresyon katsayılarının hesaplanması için kullanılan en küçük kareler yöntemi genel ifadesi Denklem (3.6) ile gösterilmiştir.

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (3.3)$$

$$Y' = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (3.4)$$

$$\varepsilon = Y - Y' \quad (3.5)$$


$$\beta = (X \cdot X^T)^{-1} X^T Y \quad (3.6)$$

3.2.2 Yapay sinir ağları

Yapay sinir ağları, beyin ve sinir sisteminin çalışma prensibine dayanan, biyolojik bir sinir ağını taklit ederek beyin ve sinir sisteminin elektriksel aktivitesini simüle eden bir teknolojidir. Diğer bir ifade ile insan beynindeki nöronların öğrenme sürecini simüle etmek için tasarlanmış, insan beyninin çalışma ilkelerinden öğrenme aracılığıyla yeni bilgiler uydurabilme, üretebilme ve keşfedebilme gibi becerileri herhangi bir destek olmaksızın otomatik bir şekilde gerçekleştirmek için geliştirilen bilgisayar tabanlı sistemlerdir. Yapay sinir ağları, veri setindeki örnekleri kullanarak elde ettikleri bilgiler


aracılığıyla olayları öğrenmeye çalışırlar ve çevreden gelecek olaylara nasıl tepkiler üretileceğini belirleyebilirler (Hopfield, 1988).

Bir biyolojik sinir hücresinin yapısı Şekil 3.2’de gösterilmekte olup bu hücre, sinapslar, soma, akson ve dendritlerden meydana gelmektedir. Sinapslar sinir hücreleri arasındaki bağlantıları ifade etmekte olup bir hücreden diğer hücreye elektrik sinyallerinin geçişini sağlayan boşluklardır. Elektrik sinyalleri somaya iletilince soma bu sinyalleri işleme alır. Daha sonra sinir hücresi kendi elektrik sinyallerini üretir ve akson vasıtasıyla bu sinyaller dendritlere gönderilir. Dendritler ise bu sinyalleri sinapslara ileterek diğer hücrelere gönderirler (Basheer ve Hajmeer, 2000).



Şekil 3.2. Biyolojik sinir hücresinin yapısı

Biyolojik sinir ağlarındaki sinir hücrelerinin sayısal bir benzetimi olan yapay sinir ağları işlemci eleman, nöron ya da düğüm olarak adlandırılan yapay sinir hücrelerine sahiptir. Yapay sinir hücresinin yapısı Şekil 3.3’te gösterilmiş olup yapay sinir hücresi üç temel elemanla ifade edilir. Üç temel eleman, nöronların her biri onun kendi ağırlıklarıyla nitelendirilmiş bağlantılar, toplama fonksiyonu ve aktivasyon fonksiyonudur (Sharma ve Sharma, 2017)



Şekil 3.3. Yapay sinir hücresi

$$\mu_k = w_1x_1 + w_2x_2 + \dots + w_mx_m = \sum_{i=1}^m w_{ki}x_i \quad (3.7)$$


Bu denklemde $x_1, x_2, \dots, x_m$ giriş sinyallerini, $w_{k1}, w_{k2}, \dots, w_{km}$ k. nöronunun ağırlıklarını göstermektedir. Şekil 3.5'teki nöron modeli b_k olarak ifade edilen harici olarak uygulanan bir eşik değeri (bias) içerir. Bias b_k , onun pozitif ya da negatif olup olmadığına bağlı olarak aktivasyon fonksiyonunun net girişini artıran ya da azaltan etkiye sahiptir. denklem 3.8'de gösterildiği gibi giriş değerleri x_i , bağlantılar üzerindeki ağırlıklar w_{ki} ile çarpılır ve toplayıcı fonksiyona bir eşik değeri (bias) ile birlikte uygulanır.

$$v_k = net = \mu_k + b_k \quad (3.8)$$

Toplayıcı fonksiyonun çıkışına (v_k) ise f aktivasyon fonksiyonu uygulanarak çıkış değeri (y_k) Denklem 3.9 deki denklem ile elde edilir.

$$y_k = f(v_k) \quad (3.9)$$

Aktivasyon fonksiyonu, hücreye gelen net girdiyi (v_k) işleme tabi tutarak hücrenin bu girdi değerine karşılık üreteceği çıktıyı belirler. Kullanılan hücre modelinin çeşidine göre değişik aktivasyon fonksiyonları kullanılmaktadır. Yaygın olarak kullanılan bu aktivasyon fonksiyonları, doğrusal fonksiyon, sigmoid fonksiyonu, tanjant sigmoid fonksiyonu olarak sıralanabilir. Fonksiyonların çıkış aralıkları ve matematiksel tanımları Şekil 3.4'te verilmiştir. Günümüzde en sık olarak çok katmanlı algılayıcı modelinde aktivasyon fonksiyonu olarak türevi alınabilen, sürekli ve doğrusal olmayan bir fonksiyon olan logaritmik sigmoid fonksiyonu kullanılmaktadır (Meher, 2010).



Şekil 3.4. Yapay sinir ağı aktivasyon fonksiyonları (Elliott, 1993)

3.2.2.1 Yapay sinir ağları öğrenme stratejileri

Yapay sinir ağlarında sinir hücreleri arasındaki bağlantıların göreceli gücünü belirleyen ağırlığı (w) ve b_k olarak ifade edilen harici olarak uygulanan eşik değeri (bias) belirleme sürecine "ağ eğitimi" denir. Ağırlıkları sürekli güncelleme ve istenen sonuca ulaşma sürecine "öğrenme" denir. Ağırlık değerleri belirli bir stratejiye göre güncellenir ve bu stratejilere "öğrenme stratejileri" adı verilmektedir (Lomonaco ve Maltoni, 2016). Bu öğrenme yaklaşımları üç grupta incelenebilir: danışmalı, danışmasız ve takviyeli öğrenme;

Danışmalı öğrenmede, girdiler ve doğru çıktı örnekleri yapay sinir ağına verilmekte, ağ girdileri işleme tabi tutularak çıktıyı üretmekte ve üretilen çıktı ile dışardan belirlenen çıktı karşılaştırılmaktadır. Ağ tarafından elde edilen çıkış, tecrübe ile elde edilen çıkış ile başka bir ifadeyle gerçek çıkış ile karşılaştırılarak hata değeri hesaplanır. Her seferinde bağlantılardaki ağırlıklar, daha iyi çıktıyı elde etmek amacıyla tekrardan ayarlanmakta ve bu işlem kabul edilebilecek bir hata seviyesine ulaşıncaya kadar devam etmektedir (Hush ve Horne, 1993)

Danışmasız Öğrenme, Danışmanlığın aksine öğretmene ihtiyacı yoktur. Bu nedenle ağ önce kendisine verilen giriş verilerine göre çıkış değerlerini hesaplar, ardından bu sonuçlara göre ağ kendi kurallarını tanımlanmaktadır (Becker, 1991).

Takviyeli Öğrenme stratejisinde, öğrenen sisteme bir öğretici destek olmaktadır. Ancak, öğretici her bir girdi setine karşılık gelen çıktı setini sisteme göstermekten ziyade sistemin kendisine gösterilen girdilere karşılık, çıktısını üretmesini umut etmekte ve üretilen çıktının doğru ya da yanlış olduğunu ifade eden bir sinyal üretmektedir. Sistem ise öğreticiden gelen bu sinyali göz önünde bulundurarak öğrenme sürecini sürdürmektedir (Lin, 1992).

3.2.3 Destek Vektör Makineleri

Destek Vektör Makinesi (DVM), hem sınıflandırma hem de regresyon problemleri için kullanılabilen istatistiksel öğrenme metoduna dayalı denetimli bir makine öğrenme algoritmasıdır. DVM genel anlamda lineer biçimde olmayan örnek uzayını, örneklerin lineer olacak şekilde ayrılmasına imkân veren bir yüksek boyuta aktararak farklı örnekler arasındaki maksimum sınırın bulunması temeline dayanır. DVM’de verilerin, lineer olarak ayrılabilmesi ve lineer olarak ayrılamamaları şeklinde iki yapı vardır. Lineer olarak ayrılmış durumdaki veriler arasında doğrudan maksimum sınırı bulmak gayet basit olmasına rağmen, lineer olarak ayrılamayan veriler, lineer olarak ayrılacakları bir uzaya aktarılarak maksimum sınırı bulunabilir (Noble, 2006).

3.2.3.1 Lineer ayrılabilirlik durumu

Veri alanındaki sınıflar, lineer bir çizgi veya hiperdüzlem ile doğrusal olarak ayrılabilirse doğrusal destek vektör makinesi olarak adlandırılır. Eğitim için kullanılacak verinin N elemanı kapsayan $X = \{x_i, y_i\}$, $i = 1, 2, \dots, N$ olduğunu durumda, $y_i \in \{-1, 1\}$ etiket değerlerini ve $x_i \in R^d$ özellik uzayını belirtmektedir. DVM, ayırıcı hiperdüzlemin örnek veri setlerine eşit mesafede olmasını hedefleyen bir tekniktir. hiperdüzlemin merkezden olan uzaklığını simgeleyen b eşik değeri ile birlikte hiperdüzlemin ağırlık vektörü olan w bulunarak sınıfları birbirinden ayıran bir hiperdüzlem belirlenmektedir. İki küme arasındaki uzaklık için en uygun hiperdüzlem denklem 3.10’ da ifade edilmektedir. Hiperdüzlemin altında ve üstünde kalan noktalar için aşağıdaki denklem 3.11 ve 3.12 geçerlidir (Bhavsar ve Panchal, 2012).


$$wx_i + b = 0 \quad (3.10)$$

$$wx_i + b \geq +1 \text{ için } y_i = +1 \quad (3.11)$$

$$wx_i + b \geq -1 \text{ için } y_i = -1 \quad (3.12)$$

Bu iki eşitlik kullanılarak denklem 3.13 türetilir. Bu şartı sağlayan hiperdüzlemin iki kümeye olan dik uzaklıkları sınır olarak isimlendirilir. Lineer olarak ayrılabilen veriler için optimum hiperdüzlem ve sınırı tanımlayan destek vektörleri Şekil 3.5’ te gösterilmiştir.

$$y_i(wx_i + b) - 1 \geq 0 \quad (3.13)$$



Şekil 3.5. Lineer olarak ayrılabilen veriler için optimum ayırıcı yüzey

En uygun hiperdüzlem sınırının maksimum seviyeye ulaşılabilmesi amacıyla $\|w\|$ değerinin minimum yapılması gerekmektedir, bu nedenle hiperdüzlemin bulunması için denklem 3.14’ de verilen koşul fonksiyonunun çözülmesi gereklidir. Koşul fonksiyonunun sınırlamaları ise denklem 3.15’ te ifade edilmiştir.

$$\min \left| \frac{1}{2} \|w\|^2 \right| \quad (3.14)$$

$$y_i (wx_i + b) - 1 \geq 0 \text{ ve } y_i \in \{1, -1\} \quad (3.15)$$


Problemin çözümünde fonksiyonun maksimum ve minimum noktalarını bulmak için sıklıkla kullanılan Lagrange formülü kullanılabilir. Lagrange formülü eşitlik 3.16' da verilmiştir. Sonuç olarak, lineer olarak ayrılabilen DVM problemin çözümü için denklem 3.17 ile ifade edilen fonksiyon elde edilmektedir.

$$L(w, b, a) = \frac{1}{2} |w|^2 - \sum_{i=1}^N a_i y_i (w x_i + b) + \sum_{i=1}^N a_i \quad (3.16)$$

$$f(x) = \text{sign} \left(\sum_{i=1}^N \lambda_i y_i (w x_i + b) \right) \quad (3.17)$$

3.2.3.1 Lineer ayrılma durumu

Veri alanı doğrusal olarak bölünemiyorsa ve sınıfları ayırabilmek için veri alanının doğrusal olarak bölünebileceği özellik uzayı adı verilen bir alana dönüştürülebiliyorsa, doğrusal olmayan destek vektör makinesi olarak adlandırılır (Şekil 3.6).



Şekil 3.6. Lineer ayrılma durumundaki veriler

Bu durumda bazı eğitim verilerinin hiperdüzlemin diğer tarafında kalması problemi ortaya çıkmaktadır ve bu problem hataları ifade eden doğal olmayan bir değişken (ξ) optimizasyon modeline eklenerek ortadan kaldırılmaya çalışılmaktadır (Denklem 3.18).

$$y_i (w x_i + b) - 1 + \xi_i \geq 0 \quad (3.18)$$


$$i = 1, 2, \dots, n$$

Bu denklemde hiperdüzlemler arası mesafeyi maksimum yapacak ve sınıflandırmadan kaynaklanan hataları minimize edecek bir C parametresi eklenmesi gerekir. C üst sınırının değeri arttıkça verilerdeki hata sayısı azalmaktadır. $C = \infty$ olduğu durumda

verilerin doğrusal olarak ayrılabilirdiği görülür. Bu durum göz önüne alınarak eşitlik güncellendiğinde denklem 3.19 elde edilir.

$$L(w, b, a, \xi, \mu) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N a_i \{y_i (wx_i + b) - 1 + \xi_i\} - \sum_{i=1}^N \mu_i \xi_i \quad (3.19)$$

Lineer olmayan veri sorunu çözümü için çekirdek fonksiyonları aracılığıyla örnekler yüksek boyutlu bir uzaya aktarılıp çözümler bu uzayda yapılabilir (Şekil 3.7).



Şekil 3.7. Lineer olmayan verilerin yüksek boyutlu uzayda ayrılması

Destek vektör makineleri, matematiksel olarak $K(x_i, x_j) = \Phi(x) \cdot \Phi(x_j)$ olarak ifade edilen kernel fonksiyonu işlevi ile doğrusal olmayan dönüşümler gerçekleştirebilir, böylece büyük ölçekli doğrusal veri ayırımına izin verilmektedir. Sonuç olarak, çekirdek fonksiyonları ile doğrusal olarak ayrılamayan iki sınıflı bir problemi çözmek için karar kuralı denklem 3.20' de gösterilmiştir (Elbisy, 2015).

$$f(x) = \text{sign} \left(\sum_i \alpha_i y_i \phi(x) \cdot \phi(x_i) + b \right) \quad (3.20)$$

Destek vektör makineleri ile yürütülecek sınıflandırma işlemi için kernel işlevinin tanımlanması ve bu işlevi kullanmak için en uygun parametrelerin belirlenmesi önemlidir. Şimdiye kadar yapılan araştırmada, çekirdek fonksiyonlar olarak temel fonksiyonların çoğu polinom, radyal, lineer, Pearson VII ve normal polinom kernelleridir. Bu işlevler şekil ve parametrelerle Çizelge 3.1'de gösterilmektedir (Amari ve Wu, 1999).

Çizelge 3.1. Destek Vektör Makineleri kernel fonksiyonları


Kernel Fonksiyonu	Formül	Parametreler
Polinom Kerneli	$K(x,y) = ((x.y) + 1)^d$	Polinom derecesi(d)
Normalleştirilmiş Polinom Kerneli	$K(x,y) = \frac{((x.y) + 1)^d}{\sqrt{((x.x) + 1)^d ((y.y) + 1)^d}}$	Polinom derecesi(d)
Radyal Tabanlı Fonksiyon Kerneli	$K(x,y) = e^{-\gamma \ x-x_i\ ^2}$	Kernel boyutu(λ)
Pearson VII Kerneli	$\frac{1}{\left[1 + \frac{2 \cdot \sqrt{\ x-y\ ^2} \sqrt{2\left(\frac{1}{w}\right) - 1}}{\sigma} \right]^\omega}$	Pearson genişliği parametreleri (σ, ω)
Lineer Kerneli	$K(x,y) = (x.y)$	Genel kernel ifadesi

Destek vektör makineleri için ifade edilen, bu matematiksel temeller veri grubunun iki sınıf olduğu durumlarda geçerli olup, daha fazla sınıf sayısının mevcut olduğu problemlerin çözümlerinde farklı yaklaşımlar bulunmaktadır. DVM’ lerde daha fazla sınıf olduğu durumda Lagrange fonsiyonunun çok sınıflı işlemler için kullanılabilmesi mümkündür. Ancak Lagrange fonsiyonunda sınıf sayısı artışıyla doğru orantılı şekilde hata miktarı da artması sebebiyle tercih edilen bir yaklaşım değildir. Diğer bir yaklaşım, destek vektör makinelerini, ikili sınıflara ayıracak şekilde çalıştırmaktır. Bu yaklaşımda bire karşı bir, bire karşı hepsi ve döngüsel olmayan graf gibi yöntemler kullanılmaktadır (Kim vd., 2003).

3.2.4 Karar ağaçları

Karar ağaçları, istatistik, veri madenciliği ve makine öğreniminde, sınıflandırma ve regresyon problemlerinin çözümünde kullanılan tahmine dayalı modelleme yaklaşımlarından biridir. Karar ağaçlarında dallarda temsil edilen öğeler hakkındaki gözlemlerden, yapraklarda temsil edilen öğenin hedef değeri hakkındaki sonuçlara gitmek için tahmin edici bir model olarak karar ağaçları kullanır. Hedef değişkenin ayrık değerler alabildiği ağaç modellerine sınıflandırma ağaçları denir; bu ağaç yapılarında yapraklar sınıf etiketlerini temsil eder ve dallar bu sınıf etiketlerine yol açan özelliklerin birleşimlerini temsil eder (Şekil 3.8). Hedef değişkenin sürekli değerler

alabileceği karar ağaçlarına regresyon ağaçları denir. Karar ağaçları, anlaşılabilirlikleri ve basitlikleri nedeniyle en popüler makine öğrenimi algoritmaları arasındadır (Myles vd., 2004).



Şekil 3.8. Karar ağaçları gösterimi

Bu yöntemde verilerin tahmin işlemini ve ağaç mekanizmasını oluştururken kökten başlanarak sorular sorulur. Eğer cevap aranacak bir soru kalmamışsa dallanma bitmiştir, kısaca bir sınıfı ya da hedefi gösteren yaprağa ulaşılmıştır. Karar ağaçlarını meydana getirirken kullanılacak algoritma önemlidir. Çünkü kullanılan algoritmaya göre ağacın dallanma yapısı ve şekli değişebilir. Literatürde, ID3, C4.5, C5, CART ve CHAID gibi çok sayıda karar ağacı algoritması geliştirilmiştir (Singh and Gupta, 2014). Karar ağaçlarının oluşturulması işlemi sonrasında herhangi bir test veri setinin sınıflandırma işlemi için kök kısımdan başlanarak oluşacak tüm çıktılar için uygun dal seçilir. Bu şekilde de yeni durum için herhangi bir iç düğüme veya test veri setinin sonuçlarını gösteren yaprak düğüme ulaşılır (Waheed vd., 2006).

3.2.4.1 Karar ağaçlarının oluşturulması

Karar ağaçları algoritmaları kök, düğüm ve dallanma kriterlerinin seçiminde izlenen yollar ile birbirinden ayrılır. Kullanılacak yöntem modelin ve veri setinin özelliklerine göre seçilmelidir. Algoritmaların seçimi model başarısını önemli ölçüde etkilemektedir. Bazı algoritmalar sadece nicel veriler üzerinde bazıları ise sadece nitel veriler üzerinde çalışmaktadır. Sıklıkla kullanılan algoritmalar; AID, CHAID, CART, ID3, C4.5, C5.0, MARS, E-CHAID, SLIQ, SPRINT ve QUEST şeklindedir. Bu algoritmalar çoğunlukla

Greedy yaklaşımını temel alarak oluşturulmaktadır. Greedy yaklaşımına göre veri setinin dallara ayrılırken hangi gruptan başlanacağı ile meydana gelen veri setini dallara ayırmak için hangi parametrenin öncelikle düşünülmesi gerektiği ile ilgili kararlar alınmaktadır (Song ve Ying, 2015).

3.2.4.2 Sınıflandırma ve regresyon ağaçları (CART)

Ağaç temelli bir karar verme yöntemi olan sınıflandırma ve regresyon ağaçları (CART), birçok uygulamada hızı ve kullanım kolaylığı nedeniyle tercih edilmektedir. Eğitim verilerinde değişken sınıflandırma olması durumunda, iki dal oluşturarak diğer karar ağaçlarından farklılık gösteren sınıflandırma ağaçları şüpheli gösterilmektedir. Eğitim verilerindeki yanıt değişkeni sürekli olduğunda regresyon ağacı olarak adlandırılmaktadır (Lewis, 2000). Genellikle iki yöntem'den ağaçların sınıflandırılması için kullanılmaktadır. Bunlar; Gini indeksi ve Twoing kuralı olarak isimlendirilmektedir.

3.2.4.2.1 Gini indeksi

Gini indeksi, bir sınıfın özelliklerinin anormalliklerini ölçmek için oluşturulmuş bir yöntemdir. Gini endeksi, basit ve hızlı bir matematiksel hesaplama algoritmadır. Bu yöntemde kullanılan işlem adımları aşağıdaki gibidir. Bu akışta k , sınıfların sayısıdır, d düğüm örneklerinin sayısıdır, n sağdaki i sınıfının örnek sayısıdır ve m , soldaki i sınıfının örnek sayısıdır. Gruptaki tüm öznitelik değerleri iki bölüme ayrılmıştır. Sağ ve sol bölümlere karşılık gelen kategori değerleri birlikte gruplandırılmıştır. Sağ ve sol Gini indeksi değerleri, özellikler için denklem 3.21 ve 3.22 ile hesaplanır. (Raileanu ve Stoffel, 2004).

$$G_{sağ} = 1 - \sum_{i=1}^k \left(\frac{n_i}{|d_{sağ}|} \right)^2 \quad (3.21)$$

$$G_{sol} = \sum_{i=1}^k \left(\frac{m_i}{|d_{sol}|} \right)^2 \quad (3.22)$$

Bu formülasyondaki t sınıfların sayısını, d sağ ve sol düğümdeki örnek sayısını, ni sağ tarafta bulunan i kategorisindeki örneklerin sayısını, mi sol tarafta bulunan i kategorisindeki örneklerin sayısını göstermektedir. Tüm i kategorisi için m eğitim veri setinde denklem 3.23 ile hesaplanır:

$$Gini_i = \frac{1}{n} \left(|d_{sol}| G_{sol} + |d_{sağ}| G_{sağ} \right) \quad (3.23)$$

Her nitelik için bulunan Gini değerlerinden en küçük değere sahip olan seçilir ve bölünme bu nitelik esas alınarak devam edilir.

3.2.4.2.2 Twoing kuralı

1984 yılında Brieman tarafından tanımlanan Twoing kuralı, ayırma kriteri tek bir sınıfı diğerinden ayırmak yerine, düğüme ait verilerin yarısını içeren ve birbirine göre heterojen sınıflar oluşturmaktadır. Bu sebeple, Twoing kuralı Gini indeksine göre daha dengeli bir yapı sunarken, işlem süresi uzamaktadır (Morgan, 2014).

Yöntemde ilk olarak eğitim veri seti nitelik değerleri baz alınarak iki kısma ayrılır. T_{sol} ve $T_{sağ}$ olacak şekilde T düğümü iki farklı dal oluşturur. Ardından bölünmelerin tamamı için olasılıklar 3.24 ila 3.27 ile gösterilen denklemler ile hesaplanır.

$$P_{sol} = \frac{T_{sol} \text{ 'daki herbir nitelik değerinin ilgili sütunundaki tekrar sayısı}}{Eğitim \text{ veri setinde bulunan kayıtların sayısı}} \quad (3.24)$$

$$P(i / T_{sol}) = \frac{T_{sol} \text{ 'daki kayıtların } i \text{ sınıfları sayısı}}{T_{sol} \text{ 'daki herbir nitelik sütunundaki tekrar sayısı}} \quad (3.25)$$

$$P_{sağ} = \frac{T_{sağ} \text{ 'daki herbir nitelik değerinin ilgili sütundaki tekrar sayısı}}{Eğitim \text{ veri setinde bulunan kayıtların sayısı}} \quad (3.26)$$

$$P(i / T_{sağ}) = \frac{T_{sağ} \text{ 'daki kayıtların } i \text{ sınıfları sayısı}}{T_{sağ} \text{ 'daki herbir nitelik sütunundaki tekrar sayısı}} \quad (3.27)$$

Denklem 3.28 ile verilen formülasyon ile uygunluk ölçütü bulunur.

$$\phi(s|T) = 2P_{sol}P_{sağ} \sum_{i=1}^n \left| P(i|T_{sol}) - P(i|T_{sağ}) \right| \quad (3.28)$$

$\phi(s|T)$ ile gösterilen uygunluk ölçütünden değeri büyük olan alınır ve bu dallanma işleminin yapılacağı satırı gösterir. Karar ağacı çizilir ve ilk adımdan itibaren ağacın alt kümesi için de aynı uygulamalar yapılır.

3.2.4.3 Karar ağaçlarında dallanma kriterleri

Karar ağaçları oluşturulurken köklerden yaprağa giden sürecin yani dallanmanın hangi kriterlere göre yapılacağı karar ağacı oluşturma sürecinin önemli bir parçasıdır. Karar ağacı yöntemi yapısı bakımından hızlı ve basit olduğu halde dallanmanın nasıl yapılacağının bilinmemesi bu yöntemin problemi konumundadır. Ağaç yapısındaki dallanmanın hangi koşullara göre yapılacağını belirlemek için bazı yaklaşımlar ortaya atılmaktadır (Breiman vd., 2017).

3.2.4.3.1 Entropi bazlı algoritmalar

Entropi, bilgi ile ilişkilendirilen ve belirsizlik hesabı için var olan bir ifadedir. Entropi değerinin sıfıra yaklaşması belirsizliğin boyutunun azaldığını ifade ederken bire yaklaşması ise belirsizlik boyutunun arttığını gösterir. Veri setinin M olduğu düşünülürse bu veri setinin entropi hesabı denklem 3.29'da verilen formülasyondaki gibidir. Burada k eleman adedidir, p ise olasılık dağılımıdır (Güldal, 2018).

$$H(M) = -\sum_{i=1}^n p_i \log_2(p_i) \quad (3.29)$$

Karar ağaçları oluşturulurken, az sayıdaki eğitim verisinden faydalanarak tüm ağaçların yapısını meydana getirmek ve bunların içinden optimum olanı seçerek dallanmaya başlanacak niteliği bulmak önemli bir işlemdir ama bunu yapmak kolay değildir. Çünkü az sayıda niteliğe ve eleman sayısına sahip olan bir eğitim kümesi için bile oluşturulacak karar ağacı sayısı çok fazladır. Bir eğitim veri setinin $K1, K2 \dots Kn$ olacak

şekilde n sayıda gruba ayrıldığını göz önüne alalım. Burada L sınıf değerleri olan herhangi bir küme için sınıfların olasılıkları denklem (3.30) ile hesaplanır.

$$P_L = \left(\frac{|K_1|}{|L|}, \frac{|K_2|}{|L|}, \frac{|K_n|}{|L|} \right) \quad (3.30)$$

$K1$ kümesine ait eleman sayısı $|K1|$ ifadesidir. L için entropi hesabı denklem 3.31 ile ifade edilir.

$$H(L) = -\sum_{i=1}^n p_i \log 2(p_i) \quad (3.31)$$

3.2.5 Gauss süreç regresyonu

Gauss süreç regresyonu (Gaussian process regression, GPR) yönteminin teorisi 1940' lı yıllarda ortaya çıkan Wiener-Kolmogorov' un tahmin teorisine ve zaman serileri analizine dayanmaktadır. Maden mühendisi D.G. Krige'nin adını taşıyan Kriging yönteminde, işleyiş olarak Gauss süreci regresyonuyla benzer yapıda olup, jeostatistiksel verilerin enterpolasyonu için sıklıkla kullanılan bir yöntemdir. Belirsizlik tahminlerindeki üstünlüğü nedeniyle, GPR doğrusal olmayan, karmaşık sınıflandırma ve regresyon sorunlarını çözmek için başarılı bir yöntemdir (Rasmussen, 2003).

GPR yaklaşımı doğrudan analitik yollarla hesaplayamadığımız fonksiyonlar hakkında çıkarım yapmak veya tahmin etmek amacıyla, parametreler yerine gözlemlerle tutarlı olan olası tüm fonksiyonlar üzerinde bir dağılım bulmamızı sağlayan parametrik olmayan bir yöntemdir (Williams ve Rasmussen, 2006).

$\{(x_i); i=1, 2, \dots, n\}$ veri setinde $x_i \in \mathbb{R}^d$ olmak üzere x_i reel değerli rassal değişkeni olan $f(x_i)$ fonksiyonu olduğunu varsayalım. Bu durumda, $f_i = f(x_i)$ ve $f = [f_1, f_2, \dots, f_n]^T$ olmak kaydıyla, sınırlı sayıdaki f_i rassal değişkenlerin herhangi bir kombinasyonunun ortak dağılımı olan $p(f_1, f_2, \dots, f_n)$ gauss dağılımını denklem 3.32 ile ifade edebiliriz:

$$p(f_1, f_2, \dots, f_n | X) \sim N(f | \mu, K) \quad (3.32)$$

Bu denklemde rassal değişkenlere ait ortalama vektörü μ ve kovaryans matrisi K denklem 3.33 ve 3.34 ile ifade edilir.

$$\mu = [\mu(x_1), \dots, \mu(x_n)]^T \quad (3.33)$$

$$K = \sum_{ij} = k(x_i, x_j) \quad (3.34)$$

$\mu(x)$ burada $f(x_i)$ rassal değişkenlerinin x_i lokasyonundaki ortalama hesaplayan fonksiyonlarını ifade eder. Yani $\mu(x)$ bir rassal değişken değil aslında bir fonksiyondur. Gauss Sürecini aslında rassal değişkenlere ait ortalama vektörü μ ve kovaryans matrisi K tanımlamaktadır. μ genellikle sıfır veya eğitim veri setinin ortalaması seçilir ve bu bir çok gerçek dünya problemine uygun bir seçimdir. Diğer taraftan K kovaryans matrisini tanımlamak Gauss sürecinde asıl anahtar noktadır. K kovaryans matrisi k pozitif tanımlı çekirdek fonksiyonlardan oluşmak durumundadır. Burada k reel değer alıp döndüren bir fonksiyondur. Kovaryans çekirdek fonksiyonu için birçok seçenek vardır: Kare üstel çekirdek, Üstel çekirdek, Matern çekirdeği, Rasyonel kuadratik çekirdek, Doğrusal çekirdek, periyodik çekirdek vb. (Wilson ve Adams, 2013). Çizelge 3.2’de Gauss süreci kernel fonksiyonları verilmiştir.

Çizelge 3.2. Gauss süreci kernel fonksiyonları

Kernel Fonksiyonu	Formül
Kare üstel çekirdek (Squared Exponential Kernel)	$k(x, x') = \sigma^2 \exp\left(-\frac{(x-x')^T \Sigma^{-1}(x-x')}{2}\right)$
Üstel çekirdek (Exponential Kernel)	$k(r) = \sigma^2 \exp\left(-\frac{r}{l}\right)$ $r = \sqrt{(x-x')^T(x-x')}$
Matern çekirdeği (Matern 3/2 Kernel)	$k_{3/2}(r) = \sigma^2 \left(1 + \frac{\sqrt{3}r}{l}\right) \exp\left(-\frac{\sqrt{3}r}{l}\right)$
Matern çekirdeği (Matern 5/2 Kernel)	$k_{5/2}(r) = \sigma^2 \left(1 + \frac{\sqrt{5}r}{l} + \frac{5r^2}{3l^2}\right) \exp\left(-\frac{\sqrt{5}r}{l}\right)$
Rasyonel kuadratik çekirdek (Rational Quadratic Kernel)	$k(x, x' \theta) = \sigma^2_f \left(1 + \frac{r^2}{2\alpha\sigma_f^2}\right)$ $r = \sqrt{(x-x')^T(x-x')}$
Doğrusal çekirdek (Linear Kernel)	$k(x, x') = \sigma^2(x-c)(x'-c)$
Periyodik çekirdek (Periodic Kernel)	$k(r) = \sigma^2 \exp\left(-\frac{2}{l^2} \sin^2\left(\frac{\pi r}{p}\right)\right)$

BÖLÜM IV

MATERYAL VE YÖNTEM

4.1 Çalışma Alanının Tanıtımı

4.1.1 Coğrafi konumu

Resmi adı Afganistan İslam Cumhuriyeti olan Afganistan, Güney Asya'da kara ile çevrili bir ülkedir ve başkenti Kabil'dir (Şekil 4.1). Afganistan'ın komşuları, batıda İran, güney doğuda Pakistan, kuzeyde Tacikistan, Özbekistan ve Türkmenistan ile kuzeydoğu komşusu Çin'dir. Afganistan 652.230 kilometrekarelik bir alanı kaplamakta ve yüzey ölçümü olarak dünyada kırk birinci ülkedir. 2019 yılı anketine göre Afganistan'ın nüfusu otuz altı milyondan fazla olup, dünya'da otuz dokuzuncu ülke olarak bilinmektedir. Farsça (Dari) ve Peştuca bu ülkenin resmi dilleridir (URL 6).



Şekil 4.1. Afganistan' ın coğrafi konumu

Afganistan'ın birçok doğal kaynağı vardır; doğal gaz, ham petrol, kömür, bakır, kromit, baryum sülfat, kükürt, kurşun, çinko, demir, tuz, değerli taşlar, uranyum ve belirtilen diğer kaynaklardır. Afganistan genelinde 1.400'den fazla maden sahası bulunmaktadır (AÜR, 2017).

Kabil, Hindu Kush dağları arasındaki dar bir vadide, 1.790 metre (5.873 ft) rakımda yer almakta ve bu da onu dünyanın en yüksek başkentlerinden biri yapmaktadır. Kabil, kış aylarında (neredeyse sadece kar olarak düşen) ve ilkbahar aylarında yoğunlaşan soğuk nedeniyle, yarı kurak bir iklime sahiptir. Güneybatı Asya'nın çoğuna kıyasla sıcaklıklar, özellikle rahatlama sağlar. Sonbaharda sıcak öğleden sonraları ve keskin serin akşamları yaşanmaktadır. Kışlar soğuktur, Ocak ayı günlük ortalama -2.3 ° C (27.9 ° F), bahar ise yılın en yağışlı zamanıdır. Güneşli koşullar yıl boyunca hakimdir. Yıllık ortalama sıcaklık 12.1 ° C'dir (53.8 ° F) ve Afganistan'ın diğer büyük şehirlerinden çok daha düşüktür (URL 7).

4.1.2 Kent nüfusu

Kabil, ülkenin doğu kesiminde bulunan Afganistan'ın başkenti ve en büyük şehridir. Aynı zamanda büyük Kabil Eyaletinin bir bölümünü oluşturan ve 22 bölgeye ayrılmış bir belediyedir. 2021'deki tahminlere göre, Kabil nüfusu 4.6 milyon olup, Afganistan'ın tüm büyük etnik gruplarını içermektedir. Afganistan'ın nüfusu 1 milyonu aşan tek şehri olan Kabil, siyasi, kültürel ve ekonomik merkezi olarak hizmet vermektedir. Hızlı kentleşme Kabil'i dünyanın 75'inci en büyük şehri haline getirmiştir (URL 8).

4.1.3 İklim özellikleri


Kabil'in iklimi, Afganistan'ın genel durumuna tabidir. Ülke, Asya'nın ortasında, dağlar boyunca ve denizden uzak olduğundan, Kabil'deki hava kirliliğini etkileyen bazı faktörler mevcuttur, dört mevsim görülmektedir. Bahar mevsimi (Mart, Nisan) başlar ve ayın sonuna (Mayıs, Haziran) kadar devam eder. Haziran ayından itibaren) Eylül ayına kadar Kabil'in ılık yaz mevsimidir. Sonbahar, Eylül ve Ekim aylarında başlar ve (Kasım ve Aralık) ayın sonuna kadar sürer. Kış ayının son üç ayı (Aralık, Ocak), (Ocak, Şubat) ve (Şubat, Mart) Kabil'in kış mevsimi çok soğuk, yağmur ve karla geçmektedir (URL 7).

4.1.4 Hava kalitesi

Afganistan'ın kentsel bölgelerindeki toz ve araç emisyonları hava kalitesini olumsuz etkileyen ana faktörlerdir. Ülke; 500.000 otomobil, 30.000 otobüs ve 50.000 kamyon

gibi hızla büyüyen rakamlarda araç yoğunluğuna sahiptir. Araçların çoğu düşük dereceli dizel yakıtla çalışmakta ve şehir merkezlerinde çok belirgin olan hava kirliliği sorunlarına neden olmaktadır. Sonbahar ve kış sonlarında hava kalitesinin, fırın, soba ve açık ateş kullanımından kaynaklanan emisyonlarla daha da kötüleştiği bilinmektedir. Halk, elektrik kesintileri ve yakacak odun eksikliği nedeniyle, zehirli dumanlara neden olabilecek bazı ambalaj malzemelerini de yakmaktadır (UNEP, 2013).


Çalışmanın bu bölümünde Şekil 4.2’de verilen Kabil şehri için Ocak 2019 ile Mart 2021 tarihleri arasına ait Sıcaklık, Çiy noktası, Nem, Rüzgar Hızı ve Basınç gibi meteorolojik parametreler ile PM_{2.5}, PM₁₀, CO, SO₂, NO₂, O₃ kirleticilerinden oluşan bir veri seti kullanılarak literatürde iyi bilinen Lineer Regresyon, Yapay Sinir Ağları, Destek Vektör Makinaları, Karar Ağaçları ve Gauss Süreç Regresyonu gibi makine öğrenmesi algoritmaları kullanılarak hava kalite indeksini tahmin eden modeller tasarlanmıştır. Veriler Afganistan Ulusal Çevre Ajansından temin edilmiştir. Kabil ilinde Afganistan Ulusal Çevre Ajansına ait 17 istasyon noktası bulunmasına rağmen sürekli ölçüm yapılamamakta veya yapılan tüm ölçümler paylaşılmamaktadır. Çizelge 4.1’ de Kabil şehrindeki hava kirliliği ölçüm istasyonu yerleri ve koordinatları verilmiştir. Şekil 4.3’te Afganistan Ulusal Çevre Ajansı tarafından hesaplanan hava kalite indeksi verilmiştir.



Şekil 4.2. Kabil’ in birinci bölgesi

Çizelge 4.1. Kabil’de hava kirliliği ölçüm istasyon yerleri ve ölçülen parametreler

Koordinatlar		Ölçülen hava kirlleticileri							
İstasyon Adı	Enlem	PM ₁₀	PM _{2.5}	SO ₂	NO	NO ₂	NO _x	CO	O ₃
Sinamai Pamir	34.513613, 69.172574	+	+	+	-	+	-	+	+
Pul Artal	34.521973, 69.162176	+	+	+	-	+	-	+	+
Çarahi Karta-E- Çahar	34.507113, 69.140471	+	+	+	-	+	-	+	+
Park Şar-E-Naw	34.533586, 69.168526	+	+	+	-	+	-	+	+
Khuşhal Khan Mina	34.525508, 69.099884	+	+	+	-	+	-	+	+
Qalai Ali Mardan	34.475372, 69.121293	+	+	+	-	+	-	+	+
Dedana-E- Darlaman	34.465799, 69.116393	+	+	+	-	+	-	+	+
Şah Şahid	34.527754, 69.225024	+	+	+	-	+	-	+	+
Makroyan Ha	34.527910, 69.202816	+	+	+	-	+	-	+	+
Qalai-E-Fathullaj	34.513613, 69.172574	+	+	+	-	+	-	+	+
Khoca Boghra	34.562880, 69.117698	+	+	+	-	+	-	+	+
Arzan-E-Qimat	34.521669, 69.201733	+	+	+	-	+	-	+	+
Daşt-E-Barçi	34.492081, 69.080614	+	+	+	-	+	-	+	+
Band-E-Qargha	34.554777, 69.030511	+	+	+	-	+	-	+	+
Maidan-E-Hawai	34.581570, 69.212803	+	+	+	-	+	-	+	+
Qala-E-Zaman Khan	34.527754, 69.225024	+	+	+	-	+	-	+	+
Park-E-Sanati	34.554796, 69.257619	+	+	+	-	+	-	+	+



Şekil 4.3. Kabil'in hava kalite indeksi

4.2 Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini

Hava kirliliğini etkileyen parametrelerin belirlenerek bir model içerisinde değerlendirilebilmesi, kirliliğe karşı alınabilecek önlemleri yönlendirebilmektedir. Ayrıca hava kalitesi ve standartlarının iyileştirilebilmesi için üretilecek çözümlerde bu modellerin kullanılması süreçleri kolaylaştırmaktadır. Hava kirliliğinin bir çok parametreye bağlı olması ve lineer olarak modellenememesi, bu konuda makine öğrenmesi tekniklerinin kullanılmasının temel nedenidir (Masih, 2019).

Makine öğrenmesi, kendi kendine öğrenebilen ve uyarlanabilen bilgisayar algoritmaları ve istatistiksel modeller kullanarak veri gruplarından bilgi çıkartımı, verilerin analizi ve veriye dayalı karar verme süreçlerinin genel adıdır. Bölüm II literatür özetinde de belirtildiği gibi, hava kirliliği üzerine farklı ülkelerde farklı şehirlere ait veriler ve çeşitli makine öğrenmesi yöntemleri kullanılarak çok sayıda çalışma yapılmıştır. Bu tez çalışmasında da Kabil şehrine ait Sıcaklık, Çiy noktası, Nem, Rüzgar Hızı ve Basınç meteoroloji parametreleri ile $PM_{2.5}$, PM_{10} , CO, SO_2 , NO_2 , O_3 kirleticilerinden oluşan bir veri seti kullanılmıştır. Veri seti literatürde iyi bilinen, Lineer Regresyon, Yapay Sinir Ağları, Destek Vektör Makinaları, Karar Ağaçları ve Gauss Süreç Regresyonu yöntemleriyle modellenmiş ve modellerin başarısı karşılaştırılmıştır.

BÖLÜM V

UYGULAMA VE BULGULAR

5.1 Veri Seti ve Verilerin Normalizasyonu

Bu çalışmada Kabil şehrine ait Ocak 2019 ile Mart 2021 tarihleri arasında ait Sıcaklık, Çiy noktası, Nem, Rüzgar Hızı ve Basınç gibi meteorolojik parametreler ile PM2.5, PM10, CO, SO2, NO2, O3 kirleticilerinden oluşan bir veri seti kullanılmıştır. Veriler, Afganistan Ulusal Çevre Ajansından temin edilmiştir. Kabil şehrinde Afganistan Ulusal Çevre Ajansına ait 17 istasyon noktası bulunmasına rağmen sürekli ölçüm yapılamamakta veya yapılan tüm ölçümler paylaşılmamaktadır. Özellikle 2019 yıllarında her güne ait veriler bulunmamakta olup, genellikle haftada 1-2 ölçüm değeri bulunmaktadır. 2020 yılından itibaren daha düzenli ölçüm yapıldığı anlaşılmaktadır. Ayrıca tüm veri seti için tek bir istasyona ait veriler de bulunmamaktadır. Her gün için şehrin farklı noktalarından alınmış kirlilik verileri bulunmaktadır. Bu nedenle elde edilebilen veri setiyle zaman serisi analizleri ve konumsal analizler gerçekleştirilememiştir. Şekil 5.1' de Afganistan Ulusal Çevre Ajansından alınmış verilere örnek gösterilmiştir.



د افغانستان اسلامي جمهوري دولت
د چاپيريال سسالتنې ملي اداره
جدول میزان پارامترهای آلودگی هوا در شهر کابل
د کابل ښارګۍ د هوا ککړتیا پارامترونو کچې جدول



Air Pollution Level in Kabul City


حجم اوسط ذرات معلق هوا به قطر (PM10-PM2.5) و پارامترهای هوا بابت برج ثور سال 1398 هـ
توسط دستگاه سياراز نقاط مختلف شهر کابل اخذ گردیده است

Ozone (O3) $\mu\text{g}/\text{m}^3$	Sulfur Dioxide (SO2) $\mu\text{g}/\text{m}^3$	Nitrogen Dioxide (NO2) $\mu\text{g}/\text{m}^3$	Carbon Monoxid (CO) mg/m^3	PM 2.5 $\mu\text{g}/\text{m}^3$	PM 10 $\mu\text{g}/\text{m}^3$	ایام هفته	تاریخ
140.40	82.48	254.92	13.16	92.196	120.953	یکشنبه	1398/2/ 1
119.59	2.55	194.50	2.66	102.56	119.59	دوشنبه	1398/2/ 2
62.49	70.45	184.90	3.133	79.723	108.986	سه شنبه	1398/2/3
79.19	29.176	16.84	3.966	76.543	74.723	چهارشنبه	1398/2/4
120.03	82.18	312.91	1.366	46.44	86.58	پنجشنبه	1398/2/14
192.35	0.08	413.50	4.66	84.016	194.54	یکشنبه	1398/2/15
108.67	35.13	358.29	5.366	63.98	104.57	سه شنبه	1398/2/17
46.696	72.74	232.49	7.533	32.236	33.143	پنجشنبه	1398/2/19
164.41	0.806	469.43	6.1	128.82	133.38	شنبه	1398/2/21
194.89	1.33	456.57	0.2	59.89	82.37	یکشنبه	1398/2/22
126.97	1.146	380.92	3.76	86.74	142.96	چهارشنبه	1398/2/25
79.18	62.19	289.05	0	26.87	77.7	شنبه	1398/2/28
78.02	22.016	255.2	4.06	50.47	62.42	دوشنبه	1398/2/30
165.21	4.83	382.67	4	61.77	98.05	سه شنبه	1398/2/31
119.864	33.36457	300.1564	4.283143	70.87529	102.8546	حد اوسط پارامتر های هوا و ذرات معلق بابت برج ثور	

SO2	NO2	O3	CO	PM2.5 $\mu\text{g}/\text{m}^3$	PM10 $\mu\text{g}/\text{m}^3$	استاندردهملي کیفیت هوا برای افغانستان
در 24 ساعت $50 \mu\text{g}/\text{m}^3$	در 24 ساعت $80 \mu\text{g}/\text{m}^3$	در 8 ساعت $100 \mu\text{g}/\text{m}^3$	در یک ساعت $30 \text{ mg}/\text{m}^3$	در 24 ساعت $75 \mu\text{g}/\text{m}^3$	در 24 ساعت $150 \mu\text{g}/\text{m}^3$	

Şekil 5.1. Afganistan Ulusal Çevre Ajansı'ndan alınmış örnek kirlilik verileri

Elde edilebilen veriler ile literatür çalışmaları da baz alınarak Sıcaklık, Çiy noktası, Nem, Rüzgar Hızı, Basınç ve PM_{2.5} parametrelerinin giriş, PM_{2.5}, PM₁₀, CO, SO₂, NO₂, O₃ kirleticileri kullanılarak hesaplanmış hava kalite indeksi çıkış/tahmin değeri olmak üzere makine öğrenmesi teknikleriyle modellenmiştir. Hava kalite indeksi Bölüm 2.7’ de verilen denklem 2.1 eşitliği kullanılarak hesaplanmıştır. Şekil 5.2’ de Kabil şehrine ait 2019, 2020, 2021 yıllarına ait aylık ortalama HKİ değerleri gösterilmiştir.



Şekil 5.2. 2019, 2020, 2021 yıllarına ait aylık ortalama HKİ değerleri

Veri setinde bulunan parametrelerin farklı birim ve sayısal ölçeklerde bulunması nedeniyle, verilerin doğrudan kullanılması, parametrelerin model içerisinde farklı oranlarda katkıda bulunmasına neden olabilmektedir. Yani sayısal olarak düşük aralıkta bulunan bir parametre, yüksek aralıkta bulunan parametreye oranla daha önemsiz kalacaktır. Veri içerisindeki en büyük ve en küçük değerlerin belirlenmesi ve verilerin bu değerlere uygun bir biçimde belirlenen bir aralıktaki sayısal değerlere dönüştürülmesi işlemi normalizasyon olarak tanımlanmaktadır. Bu işlem ile tüm veriler kendi değişim aralıklarında normalize edilerek modele eşit katkı sağlaması amaçlanmaktadır. Verilerin [1, 2] değerleri arasına normalizasyonu için kullanılan denklem 5.1’ de verilmiştir.

$$x_{norm} = \left(\frac{x - x_{min}}{x_{max} - x_{min}} \right) + 1 \quad (5.1)$$

Kullanılan makine öğrenmesi yöntemlerinde giriş parametresi olarak kullanılan Sıcaklık, Çiy noktası, Nem, Rüzgar Hızı, Basınç ve PM_{2.5} parametreleri [1, 2] aralığına normalize edilmiştir. Ayrıca modellerde çıkış değeri olarak PM_{2.5}, PM₁₀, CO, SO₂, NO₂, O₃ kirleticileri kullanılarak hesaplanmış hava kalite indeksi de [1, 2] aralığına normalize edilmiştir.

5.2 Model ve Değerlendirme

Literatürde makine öğrenmesi algoritmaları ile oluşturulan modellerin başarısını belirlemek için çok sayıda doğruluk ölçüsü bulunmaktadır. Bu tez çalışmasında hava kalite indeksinin tahmin edileceği modellerin performansını belirlemek için model uygunluk ölçüsü R² (R-squared), Ortalama Kare Hata (Mean Square Error, MSE), Ortalama Hata Kare Kökü (Root Mean Square Error, RMSE) ve Ortalama Mutlak Hata (Mean Absolute Error, MAE) kullanılmıştır. Kullanılan metriklere ait eşitlikler 5.2 ile 5.5 denklemleri ile gösterilmiştir.


$$R^2 = 1 - \frac{\sum (y_t - \hat{y})^2}{\sum (y_t - \bar{y})^2} \quad (5.2)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y})^2 \quad (5.3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y})^2} \quad (5.4)$$


$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}| \quad (5.5)$$

Ocak 2019 ile Mart 2021 tarihleri arasında Afganistan Ulusal Çevre Ajansından temin edilen toplam 536 günlük meteoroloji ve hava kirliliği verisi bulunmaktadır. Verilerin rastgele olarak %70' i (375 günlük veri) eğitim verisi olarak seçilmiş ve modellerin oluşturulmasında kullanılmıştır. Şekil 5.3' te oluşturulan modellerin genel gösterimi verilmiştir.



Şekil 5.3. HKİ tahmini için oluşturulan model yapısı

Eğitim verisi dışında kalan %30' luk (161 günlük) veri, test verisi olarak kullanılmış ve modellerin hem eğitim hem de test başarıları belirtilen metriklerle karşılaştırılmıştır. Verilerin hazırlanması ve makine öğrenmesi yöntemleriyle yapılan tüm analizler Matlab yazılımı ile gerçekleştirilmiştir. Şekil 5.4' te seçilmiş eğitim ve test verileri gösterilmiştir.



Şekil 5.4. Eğitim ve test verileri

5.2.1 Lineer regresyon ile HKİ tahmini

375 günlük eğitim verisi kullanılarak doğrusal regresyon modeli oluşturulmuş ve regresyon parametreleri en küçük kareler yöntemine göre hesaplanmıştır. Hesaplanmış parametrelere ait istatistik bilgileri Çizelge 5.1' de gösterilmiştir. Parametrelere göre oluşturulmuş regresyon eşitliği denklem 5.6 ile ifade edilmiştir.

Çizelge 5.1. Hesaplanmış regresyon katsayıları

		Estimate	SE	tStat	pValue
Bias		0.34069	0.06005	5.6735	2.8365e-08
Sıcaklık (°C)	X ₁	-0.0328	0.012321	-2.6622	0.0081044
Çiy noktası (°C)	X ₂	0.0077603	0.0086482	0.89734	0.37012
Nem (%)	X ₃	-0.0049698	0.010801	-0.46011	0.64571
Rüzgâr Hızı m/s	X ₄	0.017219	0.023225	0.7414	0.45892
Basınç (Hg)	X ₅	-0.0037962	0.013833	-0.27443	0.78391
PM2.5 (µg/m ³)	X ₆	0.81683	0.011962	68.284	4.4812e-211


$$HKI_{norm} = 0.3407 - X_1 * 0.0328 + X_2 * 0.0077 - X_3 * -0.0049 + X_4 * 0.0172 - X_5 * -0.0038 + X_6 * 0.8168 \quad (4.6)$$

Çizelge 5.2’ de eğitim ve test verilerine ait R², MSE, RMSE ve MAE performans ölçütleri gösterilmiştir.


Çizelge 5.2. Lineer regresyon performans ölçütleri

	R ²	MSE	RMSE	MAE
Eğitim Verisi	0.78	0.0050648	0.071167	0.030721
Test Verisi	0.91	0.0019954	0.044669	0.023286

Lineer regresyonla tahmin edilen ve ölçülen hava kalite indeksi değerleri eğitim verisi için Şekil 5.5’ te, test verisi için Şekil 5.6’ da gösterilmiştir.



Şekil 5.5. Eğitim verisinin lineer regresyonla tahmin edilen ve ölçülen hava kalite indeksi değerleri




Şekil 5.6. Test verisinin lineer regresyonla tahmin edilen ve ölçülen hava kalite indeksi değerleri

5.2.2 Yapay sinir ağları ile HKİ tahmini

Yapay sinir ağları ile hava kalite indeksi tahmini çalışmasında gizli katmanda sigmoid transfer fonksiyonu ve çıkış katmanında lineer transfer fonksiyonu kullanan iki katmanlı bir ileri beslemeli ağ tercih edilmiştir. Gizli katmandaki nöron sayısı 10 ve maksimum iterasyon sayısı 500 olarak ayarlanmıştır. Farklı transfer fonksiyonlarının kullanımı, katman sayısı ve nöron sayısı gibi parametreler yapay sinir ağlarının başarısını etkilemektedir. Deneme yanılma şeklinde gerçekleştirilen çalışmalarda mevcut parametrelerin başarısı yüksek olduğu için bu ağ yapısı tercih edilmiştir. Ağın eğitilmesi

aşamasında Levenberg-Marquardt optimizasyon algoritması kullanılmıştır. Şekil 5.7’ de kullanılan yapay sinir ağ modeli gösterilmiştir.




Şekil 5.7. Yapay sinir ağ modeli

Çizelge 5.3’ te yapay sinir ağları ile oluşturulmuş modelin eğitim ve test verilerine ait R^2 , MSE, RMSE ve MAE performans ölçütleri gösterilmiştir.


Çizelge 5.3. Yapay sinir ağları performans ölçütleri

	R^2	MSE	RMSE	MAE
Eğitim Verisi	0.86	0.0031837	0.056424	0.028559
Test Verisi	0.88	0.0026004	0.050994	0.029821

Yapay sinir ağları ile tahmin edilen ve ölçülen hava kalite indeksi değerleri eğitim verisi için Şekil 5.8’ de, test verisi için Şekil 5.9’ da gösterilmiştir.



Şekil 5.0.8. Eğitim verisinin yapay sinir ağlarıyla tahmin edilen ve ölçülen hava kalite indeksi değerleri



Şekil 5.9. Test verisinin yapay sinir ağlarıyla tahmin edilen ve ölçülen hava kalite indeksi değerleri

5.2.3 Destek vektör makineleri ile HKİ tahmini


Destek vektör makineleri için kernel fonksiyonunun türü ve seçilecek kernel ölçeği modelin doğrulunu etkileyen parametrelerdir. Bu tez çalışmasında DVM ile yapılan çalışmalarda Lineer Kerneli, Polinom (kuadratik ve kübik) Kerneli ve Radyal Tabanlı Fonksiyon Kernelleri farklı ölçekler için denenmiştir. Veri seti için en başarılı sonucu kübik polinom kerneli ile oluşturulan model sağlamıştır. Kernel ölçeği [0.5, 1, 5, 10, 30] olarak yapılan denemelerde en başarılı sonuç kernel ölçeği 1 değeri alındığında elde edilmiştir.

Çizelge 5.4’ de destek vektör makineleri ile oluşturulmuş modelin eğitim ve test verilerine ait R^2 , MSE, RMSE ve MAE performans ölçütleri gösterilmiştir.


Çizelge 5.4. Destek vektör makineleri performans ölçütleri

	R^2	MSE	RMSE	MAE
Eğitim Verisi	0.79	0.004779	0.069131	0.023874
Test Verisi	0.91	0.001904	0.043638	0.021823

Destek Vektör Makineleri ile tahmin edilen ve ölçülen hava kalite indeksi değerleri eğitim verisi için Şekil 5.10’ da, test verisi için Şekil 5.11’ de gösterilmiştir.



Şekil 5.10. Eğitim verisinin destek vektör makineleri ile tahmin edilen ve ölçülen hava kalite indeksi değerleri



Şekil 5.11. Test verisinin destek vektör makineleri ile tahmin edilen ve ölçülen hava kalite indeksi değerleri

5.2.4 Karar ağaçları ile HKİ tahmini


Karar ağaçları ile hava kalite indeksi tahmini çalışmasında bölünme kriteri olarak Gini indeksinden yararlanan CART algoritması, minimum yaprak boyutu 7, maksimum bölünme sayısı 10 tercih edilerek model oluşturulmuş ve doğruluk değerleri karşılaştırılmıştır. Yapılan denemelerde bölünme sayısının artırılmasının modelin eğitim doğruluğunu düşürdüğü görülmüştür.

Çizelge 5.5’ de karar ağaçları ile oluşturulmuş modelin eğitim ve test verilerine ait R^2 , MSE, RMSE ve MAE performans ölçütleri gösterilmiştir.


Çizelge 5.5. Karar ağaçları performans ölçütleri

	R^2	MSE	RMSE	MAE
Eğitim Verisi	0.88	0.0028757	0.053629	0.020006
Test Verisi	0.88	0.0026232	0.051217	0.023643

Karar ağaçları ile tahmin edilen ve ölçülen hava kalite indeksi değerleri eğitim verisi için Şekil 5.12’ de, test verisi için Şekil 5.13’ te gösterilmiştir.



Şekil 5.12. Eğitim verisinin karar ağaçları ile tahmin edilen ve ölçülen hava kalite indeksi değerleri



Şekil 5.13. Test verisinin karar ağaçları ile tahmin edilen ve ölçülen hava kalite indeksi değerleri

5.2.5 Gauss süreç regresyonu ile HKİ tahmini


Gauss süreç regresyonu ile yapılan çalışmalarda Kare üstel çekirdek (Squared Exponential Kernel), Matern çekirdeği (Matern 5/2 Kernel), Üstel çekirdek (Exponential Kernel) ve Rasyonel kuadratik çekirdek (Rational Quadratic Kernel) fonksiyonları denenmiştir. En başarılı sonuç Üstel çekirdek (Exponential Kernel) fonksiyonu ile elde edilmiştir.

Çizelge 5.6’ da gauss süreç regresyonu ile oluşturulmuş modelin eğitim ve test verilerine ait R^2 , MSE, RMSE ve MAE performans ölçütleri gösterilmiştir.


Çizelge 5.6. Gauss süreç regresyonu performans ölçütleri

	R^2	MSE	RMSE	MAE
Eğitim Verisi	0.97	0.0006408	0.025316	0.011726
Test Verisi	0.91	0.0020838	0.045649	0.026296

Gauss süreç regresyonu ile tahmin edilen ve ölçülen hava kalite indeksi değerleri eğitim verisi için Şekil 5.14’ te, test verisi için Şekil 5.15’ te gösterilmiştir.



Şekil 5.14. Eğitim verisinin gauss süreç regresyonu ile tahmin edilen ve ölçülen hava kalite indeksi değerleri



Şekil 5.15. Test verisinin gauss süreç regresyonu ile tahmin edilen ve ölçülen hava kalite indeksi değerleri

5.2.6 Makine öğrenmesi algoritmaları model sonuçları

Kullanılan modellere ait eğitim ve test verileri için R^2 , MSE, RMSE ve MAE performans ölçütleri Çizelge 5.7’ de gösterilmiştir. Tüm verilerin oluşturulan modele verilmesi ile elde edilen doğruluk değerleri Çizelge 5.8’ de gösterilmiştir.

Çizelge 5.7. Makine öğrenmesi algortimaları eğitim ve test sonuçları

Değerlendirme Kriterleri	R^2		MSE		RMSE		MAE	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
Lineer Regresyon	0.78	0.91	0.0050648	0.0019954	0.071167	0.044669	0.030721	0.023286
Yapay Sinir Ağları	0.86	0.88	0.0031837	0.0026004	0.056424	0.050994	0.028559	0.029821
Destek Vektör Makineleri	0.79	0.91	0.004779	0.001904	0.069131	0.043638	0.023874	0.021823
Karar Ağaçları	0.88	0.88	0.0028757	0.0026232	0.053629	0.051217	0.020006	0.023643
Gauss Süreç Regresyonu	0.97	0.91	0.0006408	0.0020838	0.025316	0.045649	0.011726	0.026296

Çizelge 5.8. Tüm veriler için makine öğrenmesi algoritmaları sonuçları


Değerlendirme Kriterleri	R^2	MSE	RMSE	MAE
Lineer Regresyon	0.82	0.0040226	0.063425	0.028487
Yapay Sinir Ağları	0.87	0.0030085	0.054849	0.028939
Destek Vektör Makineleri	0.83	0.0039156	0.062575	0.023258
Karar Ağaçları	0.88	0.0027999	0.052914	0.021098
Gauss Süreç Regresyonu	0.95	0.0010743	0.032776	0.016102

Çizelge 5.9’ da meteorolojik parametreler ile hava kalite indeksi arasındaki korelasyon katsayıları verilmiştir. Korelasyon analizi değişkenler arasında doğrusal bir ilişki bulunup bulunmadığını, eğer varsa bu ilişkinin yönünü ve gücünü belirler. Ancak korelasyon katsayısı değişkenler arasındaki nedensel ilişkiyi göstermez. Katsayılar incelendiğinde en yüksek korelasyonun hava kalite indeksi ile PM_{2.5} kirletici parametresi arasında ve pozitif yönlü olduğu görülmektedir. Meteorolojik parametreler ile hava kalite indeksi arasındaki korelasyon oldukça düşüktür, sıcaklık, çiy noktası, nem ve rüzgar hızı ile negatif yönlü, basınç ile pozitif yönlü bir ilişki tespit edilmiştir. Literatürde Akay (2003) ‘ün Kırıkkale ili için yaptığı çalışma, Oğuz ve Pekin (2015)’ in Ankara Keçiören bölgesinde yaptığı çalışma ve Mutlu (2019)’ un Balıkesir illeri için yaptığı çalışmalar da hava kirliliği ile sıcaklık, rüzgar hızı ve nem için negatif yönlü bağlantı olduğu ifade edilmektedir. Sıcaklığın azalması ile artan ısınma ihtiyacı ve fosil yakıt kullanımı hava kirliliğini artırmaktadır. Yüksek basınç şartları çevreden havanın bölgeye girmesini engellemekte ve dolayısı ile kirletici konsantrasyonunu artırmaktadır. Artan rüzgar hızı ile kirleticilerin dağılımına ve seyrelmesine dolayısıyla negatif korelasyonun gözlenmesine sebebiyet vermektedir. Ancak Kabil’ in topografyasının çanak biçiminde etrafı yükseltilerle çevrili olması ve esen rüzgarın kirleticilerin ortamda kalmasını engellemediği için rüzgar hızının hava kirliliğine etkisi azalmaktadır.(Ashoor, 2019). Bu tez çalışmasında veriler mevsimsel olarak değerlendirilmemiştir, literatürdeki mevsimsel çalışmalar incelendiğinde özellikle kış aylarında sıcaklık, nem, rüzgar hızı ve hava kirliliği arasındaki korelasyonun arttığı görülmektedir.

Çizelge 5.9 Meteorolojik parametreler ile hava kalite indeksi arasındaki korelasyon katsayıları

	Sıcaklık (C°)	Çiy Noktası (°C)	Nem (%)	Rüzgar Hızı (m/s)	Basınç (Hg)	PM _{2.5}	HKİ
Sıcaklık (C°)	1.0000	0.4466	-0.6247	0.5059	-0.6671	-0.1031	-0.1746
Çiy Noktası (°C)	0.4466	1.0000	-0.1008	0.0494	-0.1813	-0.0534	-0.0565
Nem (%)	-0.6247	-0.1008	1.0000	-0.4055	0.3939	-0.1982	-0.1536
Rüzgar Hızı (m/s)	0.5059	0.0494	-0.4055	1.0000	-0.6118	-0.2513	-0.2646
Basınç (Hg)	-0.6671	-0.1813	0.3939	-0.6118	1.0000	0.1995	0.2301
PM_{2.5}	-0.1031	-0.0534	-0.1982	-0.2513	0.1995	1.0000	0.9072
HKİ	-0.1746	-0.0565	-0.1536	-0.2646	0.2301	0.9072	1.0000

Regresyon katsayısına göre, Parametrelerin HKİ üzerindeki görelî önem sırası; $PM_{2.5}$, rüzgâr hızı, basınç, ortalama sıcaklık, nem ve çiy noktası şeklindedir. Şekil 5.16’ da değişken çiftleri arasındaki korelasyon katsayısı ve yönlerini belirten grafik matrisi gösterilmiştir.



Şekil 5.16. Korelasyon Matrisi

BÖLÜM VI

SONUÇLAR

Makine öğrenmesi algoritmalarının genelleme yeteneği, klasik fonksiyonel ve istatistiksel tekniklerden farklı olarak tüm parametrelerin elde edilemediği problemlerin modellenmesine olanak sağlamaktadır. Hava kirliliğinin birçok parametreye bağlı olmasından dolayı analiz ve yorumlama aşaması oldukça zordur. Her parametrenin elde edilememesi, sınırlı parametre ve veri setleriyle model kurulmasına olanak sağlaması makine öğrenmesi algoritmalarının hava kirliliği alanında kullanımını artırmaktadır.

Bilgi teknolojilerinin gün geçtikçe artması ve farklı çalışmalarda da sağladığı avantajlar nedeniyle makine öğrenmesi alanında yeni teknikler bulunmakta ve mevcut tekniklerin daha da geliştirilmesi devam etmektedir. Tez çalışmasında literatürde iyi bilinen, Lineer Regresyon, Yapay Sinir Ağları, Destek Vektör Makinaları, Karar Ağaçları ve Gauss Süreç Regresyonu yöntemleri farklı model parametreleri ile kullanılmıştır. Oluşturulan modellerde Kabil şehri için sınırlı gün ve parametre için elde edilebilen verilerle hava kalite indeksi değerleri tahmin edilmeye çalışılmıştır. Kabil şehrine ait hava kalite indeksi değerleri $PM_{2.5}$, PM_{10} , CO, SO_2 , NO_2 , O_3 kirleticileri kullanılarak elde edilmiş ve oluşturulan modellerde çıkış/tahmin değeri olarak kullanılmıştır. Sıcaklık, Çiy noktası, Nem, Rüzgar Hızı, Basınç meteorolojik parametreleri ve $PM_{2.5}$ kirletici parametresi model için giriş değeri olarak kullanılmıştır. Ocak 2019 ile Mart 2021 tarihleri arasında Afganistan Ulusal Çevre Ajansından temin edilen toplam 536 günlük meteoroloji ve hava kirliliği verilerinin rastgele olarak %70' i (375 günlük veri) eğitim verisi olarak, geri kalan %30 (161 günlük veri) test verisi olarak seçilmiştir.

Oluşturulan modeller sonucu ortaya çıkan sonuç ve gözlemler şu şekilde verilebilir:

R^2 değerinin yüksek olması model uyumunun iyi olduğunu göstermektedir ve maksimum alabileceği değer 1' dir. Eğitim verileri için en yüksek R^2 değeri 0.97 ile Gauss Süreç Regresyonu yöntemiyle elde edilmiştir. Test verileri için en yüksek R^2 değeri 0.91 ile Destek Vektör Makineleri, Gauss Süreç Regresyonu ve Lineer Regresyon yöntemleriyle elde edilmiştir. Gerek eğitim, gerekse test verileri ile elde edilen R^2 sonuçları model uyumunun, literatürdeki çalışmalarla tutarlı olduğunu

göstermektedir. Tüm veriler için makine öğrenmesi algortimaları model sonuçları incelendiğinde en uyumlu model, 0.95 R^2 değeriyle Gauss Süreç Regresyonu yöntemiyle elde edilmiştir.

Ortalama Kare Hatası (MSE) tahmin edilen sonuçların gerçek sayıdan ne kadar farklı olduğuna dair mutlak bir değeri ifade eder ve sıfıra yaklaştıkça daha iyi bir performans gösterdiği söylenebilir. Ortalama Hata Kare Kökü (RMSE) ise tahmin hatalarının standart sapmasıdır. RMSE değerinin sıfır olması modelin hiç hata yapmadığı anlamına gelir. Oluşturulan modeller için incelendiğinde eğitim verileri için en düşük MSE değeri 0.0006408 ve en düşük RMSE değeri 0.025316 ile Gauss Süreç Regresyonu yöntemiyle elde edilmiştir. Test verileri için en düşük MSE değeri 0.001904 ve en düşük RMSE değeri 0.043638 ile Destek Vektör Makineleri, yöntemiyle elde edilmiştir. Tüm veriler için makine öğrenmesi algortimaları model sonuçları incelendiğinde en düşük MSE değeri 0.0010743 ve en düşük RMSE değeri 0.032776 ile Gauss Süreç Regresyonu yöntemiyle elde edilmiştir.

Ortalama mutlak hata (MAE), hata yönlerini dikkate almadan bir dizi tahmindeki hataların ortalama büyüklüğünü ölçen, tüm tekil hataların ortalamada eşit olarak ağırlıklandırıldığı doğrusal bir metriktir. MAE değerinin sıfıra yaklaşması pozitif yada negatif yönlü tahmin hatalarının düşüklüğünü ifade etmektedir. Oluşturulan modeller için incelendiğinde eğitim verileri için en düşük MAE değeri 0.011726 ile Gauss Süreç Regresyonu yöntemiyle elde edilmiştir. Test verileri için en düşük MAE değeri 0.021823 ile Destek Vektör Makineleri, yöntemiyle elde edilmiştir. Tüm veriler için makine öğrenmesi algortimaları model sonuçları incelendiğinde en düşük MAE değeri 0.016102 Gauss Süreç Regresyonu yöntemiyle elde edilmiştir.

Eğitim ve test verileri için uygunluk ve hata değerleri incelendiğinde, test değerleri için daha iyi sonuçlar alındığı görülmektedir. Sonuç grafikleri incelendiğinde görülmektedir ki, özellikle normalize hava kalite indeksinin 1.7 (yaklaşık $HKI > 360$) ve üzerinde olduğu değerlerde tahmin başarısı düşmektedir. Rastgele olarak ayrılmış test verileri içerisinde daha az sayıda yüksek değerli hava kalite indeksi verisi bulunduğu için test verileriyle hesaplanmış model performansları daha iyi sonuçlar üretmektedir.

Tüm veriler için doğruluk kriterleri değerlendirildiğinde kullanılan 5 yöntemin de %80' nin üzerinde R^2 uygunluk değerine sahip olduğu ve tüm yöntemlerle kurulan modellerin hava kirliliği tahmini için kullanılabilir olduğu görülmüştür. Elde edilen sonuçlara göre hava kirliliği tahmininde tüm veriler için en yüksek uygunluk değeri ve en düşük hata değerleri Gauss Süreç Regresyonu ile elde edilmiş olup, makine öğrenme yöntemleri içinde en yüksek performansı göstererek ön plana çıkmıştır. Görece en kötü performansı ise Lineer Regresyon yöntemi sergilemiştir.

Kullanılan her makine öğrenmesi algoritmasının kendine ait farklı parametreleri bulunmaktadır. Yeni veri setinin kalitesi, eğitim ve test verisinin doğru seçimi model performanslarını doğrudan etkilemektedir. Bu sebeplerden dolayı farklı veriler için her teknik aynı doğruluk değerlerini vermemektedir. Tahmin doğruluğunun maksimum değerde olması için her tekniğe ait olan parametrelerin deneme yanılma yöntemiyle değiştirilerek uygulanması veya farklı optimizasyon yöntemleri ile hibrit modeller kurularak adaptif modeller oluşturulması gerekmektedir. Yine kurulacak modele hava kalitesini etkilediği bilinen, ısınma, trafik yoğunluğu, sanayi faaliyetleri, nüfus vb. parametreler giriş değeri olarak eklenirse model başarıları artacaktır.

Afganistan içinde bulunduğu politik nedenler ve gelişmişlik seviyesi sebebiyle veri erişiminin zor olduğu bir ülke olup, bu nedenle çalışmalar kısıtlı verilerle yapılabilmektedir. Uzun süreli ve sürekli veri ölçümlerinin yapılması durumunda hava kirliliği için zaman serisi analizleri de yapılabilecektir. Ayrıca farklı istasyonlardan eş zamanlı yapılacak sürekli ölçümlerle Kabil şehri içindeki hava kirliliği dağılımları da jeostatistiksel yöntemlerle belirlenebilecektir.

KAYNAKLAR

Ashoor, A.A., Kabil'deki hava kirliliğinin meteorolojik parametreler ile olan ilişkisinin istatistiksel olarak incelenmesi, Yüksek Lisans Tezi, **Karadeniz Teknik Üniversitesi Fen Bilimler Enstitüsü**, Trabzon, s. 18, 2019.

Abayomi, T., AERMOD modeling of air pollutant emissions from backup generator use in lagos, Nigeria, MSc Thesis, **The University of Texas**, Arlington, USA, 2017.

Afganistan Ülke Raporu, T.C. **Kabil Büyükelçiliği Ticaret Müşavirliği**, Shah Mahmoud Ghazi Street No:134, (45): 11s Kabul / Afghanistan, 2017.

Agerskov. U.A.S., Statistical Yearbook 2013 Denmark. **Published by Statistics Denmark**. ISBN 978-87-501-2075-9, 2013.

Altıntaş, S., Ergene havzası'nda hava kirliliğinin sağlık etkilerinin araştırılması, Yüksek Lisans Tezi, **Tekirdağ Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü**, s.6-8, Tekirdağ, 2020.

Akay, M.E., "Kırıkkale'de hava kirliliğinin meteorolojik parametrelerle ilişkisinin araştırılması", **Yanma Ve Hava Kirliliği Kontrolü VI. Ulusal Sempozyumu** 10-12 EYLÜL 2003, İzmir, 2003.

Akcan, N. ve Yeşilyurt, C., "Hava kalitesi izleme metodolojileri ve örneklem kriterler", **T.C. Sağlık Bakanlığı Refik Saydım Hıfzısıhha Merkezi Başkanlığı Çevre Sağlığı Araştırma Müdürlüğü**, Ankara, 2001.

Amari, S. and Wu, S., "Improving support vector machine classifiers by modifying kernel functions", **Neural Networks** 12(6), 783-789, 1999.

Analitis, A., Barratt, B., Green, D., Beddows, A., Samoli, E., Schwarz. J., and Katsouyanni, K., "Prediction of PM_{2.5} concentrations at the locations of monitoring sites

measuring PM₁₀ and NO_x, using generalized additive models and machine learning methods: A case study in London”, **Atmospheric Environment**, 11, 7757, 2020.

Andrews, D. F., “A robust method for multiple linear regression”, **Technometrics** 16(4): 523-531, 1974.

Ayturan, Y.A., Derin öğrenme ile havadaki partikül madde konsantrasyonu tahmini, Yüksek Lisans Tezi, KTO **Fen Bilimleri Enstitüsü**, Konya, s. 57., 2019.

Basheer, I. A. and M. Hajmeer., "Artificial neural networks: fundamentals, computing, design, and application", **Journal of microbiological methods** 43(1): 3-31, 2000.

Baş, B., Giresun ili hava kalitesinin meteorolojik parametrelerle zamansal değerlendirilmesi, Yüksek Lisans Tezi, **Atatürk Üniversitesi, Fen Bilimleri Enstitüsü**, s.90, Erzurum 2019.

Barak, W., Environment And Urban Trasnsport Management, ([Http://Heratenvironment.Blogfa.Com/Post/266](http://Heratenvironment.Blogfa.Com/Post/266)), **Kabul-Afghanistan**, 2019.

Bayram H., Dörtbudak, Z., Fişekçi, F., Murat, K. and Baytekin, B., “The Proceedings of the Panel “Effects of Air Pollution on Human Health, Air Pollution Problem in the World, Turkey and Our Region” (The Conference Hall of Dicle University, Diyarbakır 24.12.2004),” **Dicle Medical Journal**, vol. 33, 2006.

Behal, V., & Singh, R., “Personalised healthcare model for monitoring and prediction of airpollution: machine learning approach”, **Journal of Experimental ve Theoretical Artificial Intelligence**, 1–25. doi:10.1080/0952813x, 1744197, 2020.

Becker, S., “Unsupervised learning procedures for neural networks”, **International Journal of Neural Systems** 2(01n02): 17-33, 1991.

Breiman, L., Friedman, J. H., Olshen, R. A., and Stone, C. J., Classification and Regression Trees, **Routledge**, 2017.

Bhavsar, H. and Panchal, M. H., “A review on support vector machine for data classification”, **International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)** 1(10): 185-189, 2012.

Bıyık, İ., Hava kirliliğinin yapay zekâ teknikleri ile belirlenmesi, Yüksek Lisans Tezi, **Bahçeşehir Üniversitesi, Fen Bilimleri Enstitüsü**, İstanbul, s. 5-6., 2010.

Cazzolla Gatti, R., Velichevskaya, A., Tateo, A., Amoroso, N., and Monaco, A., “Machine learning reveals that prolonged exposure to air pollution is associated with SARS-CoV-2 mortality and infectivity in Italy”, **Environmental Pollution**, 267, 115471, 2020.

Choubin, B., Abdolshahnejad, M., Moradi, E., Querol, X., Mosavi, A., Shamshirband, S., and Ghamisi, P., “Spatial hazard assessment of the PM10 using machine learning models in Barcelona, Spain”, **Science of The Total Environment**, 134474, 2020.

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

Doreswamy, K. S., H., KM, Y., and Gad, I., “Forecasting air pollution particulate matter (PM_{2.5}) using machine learning regression models”, **Procedia Computer Science**, 171, 2057–2066, 2020.

Ekinci, A., Şanlıurfa’nın sosyo ekonomik durumunun hava kirliliği üzerine etkisi, Yüksek Lisans Tezi, **Harran Üniversitesi Fen Bilimleri Enstitüsü**, Şanlıurfa, 2019.

EPA, Air Topics, “<https://www.epa.gov/environmental-topics/air-topics>” , 2019.

EPA, “Particulate Matter (PM) Pollution”, United States Environmental Protection Agency, “<https://www.epa.gov/pm-pollution/particulate-matter-pm-basics#PM>”, 2019.

Elbisy, M. S., “Support vector machine and regression analysis to predict the field hydraulic conductivity of sandy soil”, **KSCE Journal of Civil Engineering**, 19(7): 2307-2316, 2015.

Elliott, D. L., “A better activation function for artificial neural networks”, ISR Technical Report TR 93-8, **Institute for Systems Research University of Maryland**, 1993.

Erdoğan, E., Sanayi kaynaklı hava kirliliğinde modellerin kullanımının karar verme sürecinde rolü, Yüksek lisans Tezi, **İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul, s.172, 2012.

Fang, C., Liu, H., Li, G., Sun, D., and Miao, Z., “Estimating the impact of urbanization on air quality in china using spatial regression models”, **Sustainability**, 7(11), 15570-15592, 2015.

Güldal, H., “Karar ağacı algoritmalarının eğitsel veriler üzerindeki performanslarının incelenmesi”, **13th International Balkan Education and Science Congress**, 2018.

Gümüş, O., Marmara bölgesi hava kalitesinin zamansal ve mekansal değişiminin istatistiksel analizi, Yüksek Lisans Tezi, **İstanbul Üniversitesi-Cerrahpaşa, Lisansüstü Eğitim Enstitüsü**, s.14, İstanbul, 2019.

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

Günel, E. A comparative study of classical and machine learning approaches for time series forecasting: an empirical analysis on exports in Turkey, MSc Thesis, **METU The Graduate School Of Natural And Applied Sciences**, Ankara, 2020.

Hopfield, J. J., “Artificial neural networks”, **IEEE Circuits and Devices Magazine** 4(5): 3-10, 1988.

Hush, D. R. and Horne, B.G., “Progress in supervised neural networks”, **IEEE signal processing magazine** 10(1): 8-39, 1993.

Incecik, S., Hava kirliliği, **Teknik Üniversite Matbaası**, s.26-41, 1994.

Irmak, E., ve Aydılek, I.B., “Hava kalite indeksinin tahmin başarısının artırılması için topluluk regresyon algoritmalarının kullanılması”, **Academic Platform Journal of Engineering and Science**, 7-3, 507-514, 2019.

Jain, A. K., Mao, J. and Mohiuddin, K. M., “Artificial neural networks: A tutorial”, **Computer** 29(3): 31-44, 1996.

Karakuş, C.B., ve Yıldız, S., “Hava kalite indeksi ile meteorolojik parametreler arasındaki ilişkinin çoklu regresyon yöntemi ile belirlenmesi”, **Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi**, 8(2), 698-711, 2019.

Kırmacı, H.K., Kahramanmaraş ili için hava kalitesinin analizi ve modellenmesi, Doktora Tezi, **Erciyes Üniversitesi Fen Bilimler Enstitüsü**, Kayseri, s.6., 2019.

Kırımhan P. D., Hava Kirliliği ve Kontrolü, Ankara: “**Turhan Kitabevi**”, 2006.

Kim, H. C., Pang, S., Je, H. M., Kim, D. and Bang, S. Y., “Constructing support vector machine ensemble”, **Pattern recognition**, 36(12), 2757-2767, 2003.

Kumar, S., Mishra, S., and Kumar Singh, S., “A machine learning-based model to estimate PM_{2.5} concentration levels in Delhi's atmosphere”, **Heliyon** 6, e05618, 2020.

Kunt, F., Bulanık mantık ve yapay sinir ağları yöntemleri kullanılarak Konya il merkezi hava kirliliği modellenmesi, Doktora tezi, **Selçuk Üniversitesi Fen Bilimleri Enstitüsü**, Konya, s.1., 2014.

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

Lewis, R. J., An introduction to classification and regression tree (CART) analysis. **Annual meeting of the society for academic emergency medicine in San Francisco, California**, Citeseer, 2000.

Lin, L., Reinforcement learning for robots using neural networks, PhD Thesis, **Carnegie Mellon University**, Ann Arbor, 1992.

Lomonaco, V. and Maltoni, D., “Comparing incremental learning strategies for convolutional neural networks”, **IAPR Workshop on Artificial Neural Networks in Pattern Recognition**, Springer, 2016.

Ma, J., Cheng, J. C. P., Lin, C., Tan, Y., and Zhang, J., “Improving air quality prediction accuracy at larger temporal resolutions using deep learning and transfer learning techniques”, **Atmospheric Environment**, 214, 116885. doi:10.1016/j.atmosenv.116885, 2019.

Mangır, N., İstanbul'da 2010 yılına ait hava kirliliği envanterinin halk sağlığı açısından değerlendirilmesi, Yüksek Lisans Tezi, **İstanbul Üniversitesi Sağlık Bilimleri Enstitüsü**, İstanbul, 2014.

Masih, A., “Machine learning algorithms in air quality modeling”, **Global Journal of Environmental Science and Management**, 5(4): 515-534, 2019.

Mayer, H., “Air Pollution in Cities”, **Atmospheric Environment**, 33, 4029– 4037, 1999.

Meher, P. K., “An optimized lookup-table for the evaluation of sigmoid function for artificial neural networks”, **18th IEEE/IFIP International Conference on VLSI and System-on-Chip**, IEEE, 2010.

Menteşe S., Bakar, C., Mirici N. A., Oymak S., and Otkun M. T., “Associations between respiratory health and ambient air quality in Çanakkale, Turkey: A long-term cohort study”, **Environmental Science and Pollution Research**, 25:12915-12931, 2018.

Morcalı, M. H. ve Akan, D. S., “Kahramanmaraş hava kirliliği kaynaklarının izlenmesi ve belirlenmesi”, **Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik Bilimleri Dergisi**, 20(2), s.105-115, 2017.

Morgan, J., “Classification and regression tree analysis”, Technical Report No. 1, **Boston University** 298, 2014.

Mutlu, A. “Hava kalitesi ve meteoroloji: korelasyon, trend ve epizot analizleri” **Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, 9(4), 724-741, 2019.

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

Myles, A. J., Feudale, R. N., Liu, Y., Woody, N. A., and Brown, S. D., “An introduction to decision tree modeling”, **Journal of Chemometrics: A Journal of the Chemometrics Society** 18(6): 275-285, 2004.

NEPA, Birleşmiş Milletler İklim Değişikliği Sözleşmesi, Afganistan İslam Cumhuriyeti, **Ulusal Çevre Koruma Ajansı**, Afganistan, 2012.

Noble, W. S., “What is a support vector machine?” **Nature Biotechnology**, 24(12): 1565-1567, 2006.

Nuhoğlu, A.Z., Isparta kent merkezi hava kalitesi ve meteorolojik faktörler arasındaki ilişkinin veri madenciliği süreci ile tespit edilmesi, Yüksek Lisans Tezi, **Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü**, Isparta, s.1., 2014.

Oğuz, K., Pekin, M.A., “Meteorolojik koşulların hava kirliliği üzerine etkilerinin incelenmesi: Keçiören ilçesi örneği”, **VII. Uluslararası Katılımlı Atmosfer Bilimleri Sempozyumu**, İstanbul, 2015.

Özcan H. K., “Long Term variations of the atmospheric air pollutants in Istanbul city”, **International Journal of Environmental Research and Public Health**, 9(3), 781-790, 2012.

Özdemir, F., Türkiye genelinde kükürt dioksit ve partiküler madde kirlilik dağılımlarının analizi, Yüksek Lisans Tezi, **YTÜ Fen Bilimleri Enstitüsü**, s.4-5, İstanbul, 2008.

Özçomak, D., Analysis of air pollution over Izmir via atmospheric modeling, MSc Thesis, **İTÜ Eurasia Institute of Earth Sciences**, Istanbul, Turkiye, 2016.

Pope, I. C. and Dockery, D. W., “Health effects of fine particulate air pollution: Lines that connect”, **Journal of the Air & Waste Management Association**, 56, 709-742, 2006.

Raileanu, L. E. and Stoffel, K., “Theoretical comparison between the gini index and information gain criteria”, **Annals of Mathematics and Artificial Intelligence**, 41(1): 77-93, 2004.

Rasmussen, C. E., Gaussian Processes in Machine Learning, **Springer**, 2003.

Sarı, E.N., Hava kirliliği ve konut dokusu arasındaki ilişkinin analizi: Erzurum örneği, Yüksek Lisans Tezi, **Atatürk Üniversitesi Fen Bilimleri Enstitüsü**, Erzurum, s.1., 2019.

Sağlar, E., İzmir ile hava kirliliğinin alansal ve zamansal olarak analizi, Yüksek Lisans Tezi, **Atatürk Üniversitesi Fen Bilimler Enstitüsü**, Erzurum, 1s., 2019.

Selçuk, B., Hava kalitesi açısından Çanakkale ilinin emisyon potansiyeli, Yüksek Lisans Tezi, **Çanakkale Onsekiz Mart Üniversitesi Fen Bilimleri Enstitüsü**, s.7-8, Çanakkale, 2019.

Sharma, E., Deo, R.C., Prasad, R., Parisi, A.V., “A hybrid air quality early-warning framework: An hourly forecasting model with online sequential extreme learning

machines and empirical mode decomposition algorithms”, **Science of the Total Environment**, 135934, 2020.

Sharma, S. and Sharma, S., “Activation functions in neural networks”, **Towards Data Science**, 6(12): 310-316, 2017.

Singh, S. and Gupta, P., “Comparative study ID3, cart and C4. 5 decision tree algorithm: a survey”, **International Journal of Advanced Information Science and Technology**, (IJAIST) 27(27): 97-103, 2014.

Song, Y.-Y., and Ying, L., “Decision tree methods: applications for classification and prediction”, **Shanghai archives of psychiatry**, 27(2): 130, 2015.

Sözer, M., Estimation of total carbon, hydrogen, sulfur and gross calorific value by using multi lineer regression method, MSC Türkiye, **İTÜ Graduate School of Science Engineering and Technology**, İstanbul, s.51., 2018.

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

Şaşa, N., PM₁₀ parametresinin makine öğrenmesi algoritmaları ile mekansal analizi, Kayseri ili örneği, Yüksek Lisans Tezi, **Niğde Ömer Halisdemir Üniversitesi, Fen Bilimleri Enstitüsü**, Niğde, 2021.

Tel, M., Niğde il merkezinde evsel ısınma kaynaklı emisyonların aermod view kalitesi modeli kullanılarak incelenmesi, Yüksek Lisans Tezi, **Niğde Ömer Halisdemir Üniversitesi, Fen Bilimleri Enstitüsü**, Niğde, s.13., 2019.

Torabi, E. and Nogami, A., “Environmental assessment of suspended particulate matter over the Kabul City, Afghanistan” **In Proc. 44rd Annual Meeting of Environmental Systems Research**, Conference of Japan Society of Civil Engineers, Tokyo Metropolitan University, Tokyo, Japan, 2016.

Türküm, A., Kocaeli atmosferinde uçucu organik bileşiklerin ve inorganik gazların dağılımları, kaynakları ve sağlık risklerinin belirlenmesi, Doktora Tezi, **Kocaeli Üniversitesi Fen Bilimleri Enstitüsü**, Kocaeli, 2018.

URL 1, Ambient (outdoor) air quality and health, [https://www.who.int/news-room/fact-sheet/detail/ambient-\(outdoor\)-air-quality-and-health](https://www.who.int/news-room/fact-sheet/detail/ambient-(outdoor)-air-quality-and-health), 15.06.2021.

URL 2, Hava kalitesi izleme sistemi, T.C. Çevre ve Şehircilik Bakanlığı, <https://sim.csb.gov.tr/Home/HKI?baslik=HAVZA%20SİSTEMİ>, 15.06.2021.

URL 3, Hava kalitesi değerlendirme ve yönetimi yönetmeliği, <http://www.mevzuat.gov.tr/Metin.Aspx?MevzuatKod=7.5.12188&MevzuatIlki=0>, Resmi Gazete , Tarih 06.06.2008 ve Sayı 26898, 13, 5, 2021.

URL 4, Dünya Sağlık Örgütü, <https://www.yesilist.com/dunya-saglik-orgutu-zengin-ve-fakir-ulkelerdeki-hava-kirliligi-oranlarindaki-esitsizlik-buyuyor/> , 06.16.2021.

URL 5, https://eeas.europa.eu/delegations/afghanistan_en, 06.16.2021.

URL 6, <https://tr.wikipedia.org/wiki/Afganistan>, 13,18,2021.

URL 7, <https://en.wikipedia.org/wiki/Kabul#Climate>, 13,08, 2021.

URL 8, <https://en.wikipedia.org/wiki/Kabul>, 13,08, 2021.

United Nations Environment Programme, Post-Conflict Environmental Assessment Afghanistan, ISBN: 92-1-158617-8, Switzerland/2003. **UNEP** (180): 47s, 2013.

Wang, D., Wei, S., Luo, H., Yue, C., and Grunder, O., “A novel hybrid model for air quality index forecasting based on two-phase decomposition technique and modified extreme learning machine”, **Science of the Total Environment**, 580, 719–733, 2017.

Williamson S., Fundamentals of Air Pollution, **Addison-Wesley Reading**, MA, 1973.

Wong, P.Y., Lee, H.Y., Chen, Y.C., Zeng, Y.T., Chern, Y.R., Chen, N.T., Candice lung, S.C., Su, H.J., and Wu, C.D., “Using a land use regression model with machine learning to estimate ground level PM_{2.5}”, **Environmental Pollution**, 116846, 2021.

Waheed, T., Bonnell, R., Prasher, S. O., and Paulet, E., "Measuring performance in precision agriculture: CART—A decision tree approach", **Agricultural Water Management** 84(1-2): 173-185, 2006.

Williams, C. K. and Rasmussen, C. E., Gaussian Processes for Machine Learning, MIT Press Cambridge, MA, 2006.

Wilson, A. and Adams, R., Gaussian process kernels for pattern discovery and extrapolation. **International Conference on Machine Learning**, PMLR, 2013.

Yeşilyurt, C., Hava kirliliği izleme metodolojileri ve örneklem kriterleri, T.C. Sağlık Bakanlığı, Refik Saydam Hıfzısıhha Merkezi Başkanlığı Çevre Sağlığı Araştırma Müdürlüğü, ISBN 975-590-032-2, Ankara, 2001.

Zeng, Z., Gui, K., Wang, Z., Luo, M., Geng, H., Ge, E., An, J., Song, X., Ning, G., Zhai, S., and Liu., H., “Estimating hourly surface PM_{2.5} concentrations across China from high-density meteorological observations by machine learning”, **Atmospheric Research**, 105516, 2021.

EKLER

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
1.01.2019	137	130.93	136.14	136.2	151.17	133.7
2.01.2019	159	142.12	175.48	154.59	152.5	164.18
5.01.2019	153	147.12	162.09	151.78	153	153.23
6.01.2019	162	160.52	176.34	162.89	163	169.71
7.01.2019	389	261.15	301.36	256.53	373.75	307.94
8.01.2019	199	217.34	247.27	218.8	258.75	228.65
9.01.2019	321	259.45	296.4	254.73	273	304.91
12.01.2019	380	218.85	244.24	211.31	258.75	322.16
13.01.2019	494	263.71	442.86	260.7	373.75	441.15
14.01.2019	500	251.07	376.79	248.52	373.75	433.48
15.01.2019	500	477.18	496.74	504.14	436.75	490.63
16.01.2019	158	153.48	163.7	157.08	158.2	157.28
22.01.2019	165	160.94	157.16	161.65	162.86	164.69
23.01.2019	158	154.72	170.34	158.78	156.6	165.44
24.01.2019	155	149.83	163.16	156.28	156.6	160.63
25.01.2019	157	153.46	180.51	161.23	156.6	165.84
26.01.2019	308	186.63	286.28	191.22	210	291.41
2.02.2019	183	192.35	252.48	193.18	210	219.58
3.02.2019	163	160.69	191.23	168.67	163	169.73
4.02.2019	362	346.52	373.22	330.7	376.75	346.96
7.02.2019	188	201.37	198.75	192.14	210	193.05

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
9.02.2019	175	138.42	146.94	147.72	175	158.71
10.02.2019	157	150.77	177.75	159.5	156.29	173.65
11.02.2019	127	134.06	154.67	144.92	122.2	139.24
16.02.2019	139	138.73	145.01	146.21	139.67	145.35
17.02.2019	158	154.04	164.16	153.91	158.2	157.55
18.02.2019	117	118.28	121.09	120.29	122.2	121.7
19.02.2019	171	174.82	173.87	171.78	182.5	168.66
23.02.2019	121	133.98	138.44	141.42	122.2	129.56
24.02.2019	159	156.42	144.98	156.36	163	157.95
25.02.2019	170	170.32	161.71	168.26	169.63	171.03
27.02.2019	212	139.67	136.22	149.84	175	146.55
4.03.2019	176	180.91	169.42	176.06	175.33	178.9
5.03.2019	163	160.75	149.34	159.23	163	159.41
6.03.2019	125	131.16	120.61	135.1	134.33	129.7
10.03.2019	165	164.45	150.76	160.71	164.22	163.02
12.03.2019	119	128.94	136.56	133.3	151.17	125.58
16.03.2019	157	149.52	167.79	155.87	169.75	161.07
17.03.2019	156	130.89	150.37	140.93	151.17	150.95
18.03.2019	179	185.46	175.39	181.29	179.33	179.26
24.03.2019	169	168.38	175.04	168.56	169.63	167.85
25.03.2019	195	165.7	178.42	165.67	176.5	183.01

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
28.03.2019	149	137.96	144.34	144.6	152.5	146.79
31.03.2019	135	132.03	146.05	139.12	134.33	136.13
1.04.2019	149	138.38	154.33	147.03	152.5	145.29
2.04.2019	164	150.09	160.99	154.66	163	162.15
4.04.2019	156	144.28	156.48	151.5	169.75	156.55
6.04.2019	180	182.47	183.95	179.36	179.33	183.59
7.04.2019	197	208.79	207.18	201.22	198.57	202.49
8.04.2019	168	164.27	173.64	165.02	167.44	171.96
10.04.2019	157	146.91	150.89	151.59	156.29	154.84
18.04.2019	129	128.14	138.07	136.67	151.17	134.65
20.04.2019	135	133.21	150.07	139.66	131.6	138.11
21.04.2019	170	167.17	173.71	167.84	169.43	174.78
22.04.2019	175	174.79	178.37	173.45	175.33	187.42
23.04.2019	164	158.38	162.23	160.49	163	159.9
24.04.2019	162	156.54	156.22	157.2	161.67	160.31
4.05.2019	141	130.84	145.16	143.12	134.33	139.71
5.05.2019	182	159.67	165.72	163.72	192.5	159.58
7.05.2019	155	143.96	155.03	154.94	169.75	153.67
9.05.2019	126	119.22	144.41	134.72	134.33	130.21
11.05.2019	189	196.07	194.56	191.77	189.43	222.33
12.05.2019	185	141.44	150.87	149.95	169.75	171.8
15.05.2019	167	163.47	172.68	164.53	167.44	170.67
18.05.2019	137	115.13	141.82	130.81	134.33	130.07

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
20.05.2019	138	133.17	147.56	143.25	139.67	145.47
21.05.2019	155	141.81	157.44	150.22	169.75	153.47
22.05.2019	173	171.73	173.87	173.17	173.57	173.11
25.05.2019	121	119.79	135.68	128.1	134.33	125.45
26.05.2019	126	127.7	136.66	135.44	134.33	144.89
27.05.2019	161	121.42	137.63	141.92	134.33	154.47
28.05.2019	168	126.41	139.34	140	134.33	153.98
29.05.2019	161	126.22	142.77	145.98	134.33	138.84
30.05.2019	162	152.54	163.98	158.69	163	162.82
1.06.2019	126	124.16	145.39	141.56	134.33	131.02
10.06.2019	185	190.7	184.35	186.61	186.6	185.79
22.06.2019	170	167.27	169.4	169.65	169.43	166.72
27.06.2019	193	203.42	182.01	198.88	192.6	200.12
29.06.2019	164	163.31	136.73	83.73	164.22	189.64
30.06.2019	163	153.82	174.85	152.86	163	155.52
2.07.2019	131	130.57	139.23	144.81	131.6	136.35
3.07.2019	206	215.7	209.08	210.46	206.4	207.45
7.07.2019	165	158.06	166.15	160.86	192.5	163.21
8.07.2019	172	170.06	165.71	169.49	173.57	173.39
13.07.2019	164	156.43	166.72	159.67	164.22	163.15
15.07.2019	235	241.54	216.9	240.52	233.89	232.6
20.07.2019	171	166.2	175.66	169.19	169.43	165.19
23.07.2019	192	197.68	202.31	190.08	192.6	193.04

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
27.07.2019	181	182.83	200.76	176.97	182	180.3
31.07.2019	179	178.97	185.06	173.21	182	178.69
3.08.2019	163	155.29	163.76	159.98	163	162.05
4.08.2019	169	163.93	168.51	165.32	169.43	168.74
5.08.2019	167	161.12	164.43	163.36	167.44	166.95
14.08.2019	183	185.51	189.48	186.08	182	182.16
17.08.2019	163	155.41	167.23	160.11	163	162.09
21.08.2019	152	136.57	152.13	152.25	152.5	149.2
22.08.2019	178	177.61	183.72	173.51	176.86	178.76
26.08.2019	197	207.32	208.55	203.55	198.57	233.74
27.08.2019	182	183.85	186.98	183.77	182	202.86
28.08.2019	185	187.11	202.47	181.39	184.4	194.06
2.09.2019	207	217.07	209.01	211	206.4	209.03
3.09.2019	181	181.32	183.99	182.73	182	180.28
11.09.2019	178	177.42	176.94	177.74	176.86	178.31
14.09.2019	189	195.31	194	191	189.43	197.92
30.09.2019	264	263.91	246.24	257.88	260.33	273.54
1.10.2019	500	207.95	203.3	202.27	272.75	374.64
2.10.2019	253	255.36	243.28	248.56	260.33	256.64
3.10.2019	208	221.25	212.18	217.15	208.8	211.45
5.10.2019	168	167.46	164.04	163.44	167.44	166.67
6.10.2019	157	150.48	150.46	150.8	156.29	155
7.10.2019	139	135.34	145.7	144.65	139.67	146.59

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
13.10.2019	421	396.88	404.1	436.37	436.75	402.87
14.10.2019	275	272.59	296.33	268.89	274	273.16
15.10.2019	370	347.92	381.79	365.4	376.75	364.33
16.10.2019	283	278.89	283.54	274.52	280.75	281.25
17.10.2019	231	238.92	224.66	231.8	233.89	249.49
19.10.2019	156	146.82	153.1	152.74	156.29	155.67
21.10.2019	157	146.93	158.87	151.62	169.75	157
22.10.2019	175	176.62	180.06	173.46	175.33	177.78
23.10.2019	200	213.97	213.34	206.43	198.57	200.37
24.10.2019	253	256.63	249.97	249.51	260.33	253.1
26.10.2019	193	203.32	199.7	196.93	194	194.25
27.10.2019	180	183.29	182.77	180.06	183.83	181.13
28.10.2019	424	400.99	397.5	406.21	436.75	402.24
29.10.2019	183	187.45	187.66	185.06	182	183.28
30.10.2019	156	147.22	155.49	150.65	156.29	154.48
31.10.2019	153	143.68	150.66	144.94	153	144.19
2.11.2019	137	134.59	141.73	146.87	139.67	164.72
3.11.2019	207	219.67	215	215.47	206.4	207.49
4.11.2019	174	175.93	179.6	174.11	173.57	173.9
5.11.2019	166	163.14	166.67	161.64	192.5	165.22
6.11.2019	165	163.24	154.05	163.17	164.22	164.23
7.11.2019	183	189.71	195.71	184.64	183.83	176.15
9.11.2019	221	232.03	237.41	225.36	222.5	226.84

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
10.11.2019	276	276.31	274.09	271.92	274	275.2
11.11.2019	226	235.74	239.98	228.03	222.5	219.66
12.11.2019	172	172.64	180.06	169.35	176.5	173.35
13.11.2019	242	248.4	247.5	240.24	244.13	239.32
14.11.2019	183	190.2	193.56	186.79	184.4	184.62
16.11.2019	179	128.19	143.99	142.77	151.17	170.91
17.11.2019	197	210.5	210.74	210.52	272.75	205.5
18.11.2019	181	149.22	168.11	157.66	169.75	174.76
19.11.2019	251	256.06	255.37	250.79	244.13	247.15
20.11.2019	165	154.5	163.69	155.73	161.67	161.09
21.11.2019	160	155.53	180.31	171.37	161.67	165.78
23.11.2019	187	128.56	149.07	141.43	151.17	168.02
24.11.2019	153	143.65	155.03	147.88	152.5	148.93
25.11.2019	186	180.42	188.61	180.2	176.86	176.55
26.11.2019	258	262.59	264.27	261.57	273	256.74
27.11.2019	305	300.67	305.93	295.78	312.44	303.91
28.11.2019	187	197.89	226.41	195.95	184.4	226.07
30.11.2019	274	275.61	301.24	271.42	274	292.89
1.12.2019	282	282.01	306.04	277.67	280.75	287.07
2.12.2019	220	232.52	250.24	227.2	222.5	231.08
3.12.2019	414	384.99	411.97	395.7	436.75	397.42
4.12.2019	255	260.2	278.46	255.14	273	264.15
5.12.2019	312	305.56	325.48	302.91	312.44	307.59

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
7.12.2019	433	415.1	455.2	440.66	436.75	432.39
8.12.2019	298	294.62	320.17	293.27	294.86	302.66
9.12.2019	266	268.56	269.85	264.88	260.33	264.32
10.12.2019	179	184.49	194.84	184.28	183.83	179.54
11.12.2019	180	183.88	179.73	181.15	176.86	174.12
12.12.2019	172	175.78	170.85	173.4	173.57	167.37
14.12.2019	216	230.67	253.46	223.93	214	238.94
15.12.2019	180	187.74	207.61	184.02	210	194.06
16.12.2019	219	232.66	290.32	229.58	222.5	322.8
17.12.2019	305	301.22	369.48	303.63	312.44	326.88
18.12.2019	354	339.61	348.43	347.6	345.62	352.22
19.12.2019	234	243.95	255.99	241.03	233.89	238.06
20.12.2019	258	263.58	285.39	257.76	273	266.46
21.12.2019	201	218.39	235.11	209.87	202.71	219.1
22.12.2019	255	260.93	303.31	257.54	273	332.83
23.12.2019	237	247.02	271.06	239.61	233.89	251.87
24.12.2019	352	338.55	360.88	350.82	345.62	353.55
25.12.2019	419	386.24	417.44	423.33	436.75	416.63
26.12.2019	467	456.51	476.45	530.06	436.75	466.83
27.12.2019	301	298.09	324.58	298.42	294.86	307.13
28.12.2019	352	338.45	363.82	350.58	345.62	352.64
29.12.2019	384	364.34	395.58	384.02	376.75	385.49
30.12.2019	213	228	235.03	217.29	214	214.2

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
31.12.2019	144	140.14	143.79	145.57	139.67	141.28
1.01.2020	171	119.29	133.71	145.18	203.5	163.19
2.01.2020	136	124.63	145.52	158.86	139	153.49
3.01.2020	152	143.44	153.98	152.23	175	155.68
4.01.2020	219	233.12	231.24	228.79	258.75	221.86
5.01.2020	139	125.27	142.22	136.08	139	148.68
6.01.2020	188	115.55	136.35	124.69	203.5	161.31
7.01.2020	141	132.46	167.42	141.7	158.33	149.22
8.01.2020	172	163.67	185.67	167.81	162.86	173.84
9.01.2020	162	160.97	182.91	168.01	162.86	166.65
10.01.2020	164	164.39	265.77	177.56	163	187.86
11.01.2020	186	177.61	198.77	189.8	182.5	193.63
12.01.2020	138	123.28	145.83	109.26	139	137.43
13.01.2020	191	136.01	180.57	110.29	175	173.17
14.01.2020	170	173.12	174.83	177.47	182.5	174.39
15.01.2020	176	173.36	184.89	177.98	182.5	180.42
16.01.2020	186	198.49	214.79	198.04	210	191.53
17.01.2020	183	193.29	200.84	189.44	210	186.06
18.01.2020	186	172.5	195.43	174.99	182.5	181.75
19.01.2020	141	126.3	140.91	145.5	158.33	148.97
20.01.2020	186	119.59	128.7	134.22	203.5	135.79
21.01.2020	240	249.35	246.85	257	373.75	244.36
22.01.2020	183	173.83	197.75	189.53	182.5	194.42

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
23.01.2020	176	182.1	217.79	192.58	210	199.98
24.01.2020	156	150.87	150.55	157.42	156.29	166.19
25.01.2020	188	169.2	160.84	170.61	182.5	180.46
26.01.2020	145	127.63	136.85	140.11	158.33	144.72
27.01.2020	190	129.97	140.03	138.03	158.33	147.87
28.01.2020	189	203.51	214.31	199.85	210	206.75
29.01.2020	189	201.58	194.54	196.65	210	191.83
30.01.2020	166	166.38	159.75	167.98	192.5	169.74
31.01.2020	156	150.37	145.92	150.3	156.29	158.83
1.02.2020	198	215.22	206.01	209.9	258.75	202.65
2.02.2020	145	125.09	128.38	141.05	158.33	145.17
3.02.2020	147	140.79	142.4	149.81	175	148.32
4.02.2020	161	156.76	157.79	162.98	161.67	161.59
5.02.2020	186	132.15	136.48	144.71	158.33	165.8
6.02.2020	173	176.8	168.55	174.02	182.5	174.27
7.02.2020	156	150.05	165.77	162.87	156.6	173.9
8.02.2020	280	281.41	301.76	277.72	280.75	294.59
9.02.2020	146	128.13	142.17	147.86	158.33	149.54
10.02.2020	225	162.75	168.19	174.46	192.5	201.94
11.02.2020	178	133.45	150	165.82	175	176.8
12.02.2020	195	135.09	151.24	167.98	175	180.53
13.02.2020	165	163.3	156.16	165.26	192.5	165.17
14.02.2020	143	138.88	150.66	148.8	157.71	150.32

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
15.02.2020	145	138.83	141.17	148.46	157.71	149.01
16.02.2020	152	143.81	153.93	147.82	157.71	156.5
17.02.2020	187	124.65	143.56	144.58	158.33	169.62
18.02.2020	169	168.05	162.67	164.02	176.5	167.24
19.02.2020	176	167.76	154.02	164.87	169.63	175.29
20.02.2020	189	200.14	187.05	195.52	194	197.36
21.02.2020	164	159.36	170.31	166.28	162.86	166.76
22.02.2020	257	259.3	263.34	252.56	260.33	252.77
23.02.2020	179	182.49	190.18	179.92	179.33	181.41
24.02.2020	157	147.98	155.3	155.83	156.6	157.08
25.02.2020	185	190.95	192.3	185.29	184.4	184.62
26.02.2020	264	264.23	262.58	260.21	260.33	249.82
27.02.2020	132	134.12	121.77	126.96	131.6	123.05
28.02.2020	97	123.45	114.84	106.26	104.71	108.98
29.02.2020	171	170.47	156.26	167.22	169.63	165.13
1.03.2020	177	178.28	168.36	177.52	176.86	174.96
2.03.2020	253	256.38	249.78	255.61	260.33	250.58
3.03.2020	174	174.57	160.22	170.25	173.57	182.65
4.03.2020	339	113.5	129.9	89.75	203.5	258.6
5.03.2020	76	115.33	132.55	86.04	70.12	99.35
7.03.2020	116	115.45	132.79	122.36	203.5	125.63
8.03.2020	129	134.98	132.77	141.94	157.71	133.89
10.03.2020	102	124.9	120.54	110.52	115.43	102.61

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
11.03.2020	100	122.63	144.14	104.66	115.43	121.79
11.03.2020	168	168.89	176.57	160.94	169.63	174.75
12.03.2020	174	176.43	164.31	167.36	173.57	174.59
13.03.2020	119	129.15	130.51	138.38	115.43	122.93
14.03.2020	173	173.81	168.74	168.99	173.57	172.16
15.03.2020	173	172.64	178.22	173.99	173.57	175.34
24.03.2020	61	108.83	103.75	88.02	70.12	75.42
25.03.2020	107	125.33	115.47	107.91	104.71	94.4
29.03.2020	91	119.2	120.27	122.95	104.71	96.74
30.03.2020	72	110.06	106.26	103.28	70.12	81.31
31.03.2020	46	104.77	109.64	81.79	70.12	64.49
1.04.2020	129	133.69	122.37	119.86	131.6	129.89
2.04.2020	168	165.66	163.35	163.41	169.63	166.56
4.04.2020	78	113.45	125.37	124.94	70.12	90.3
5.04.2020	72	112.01	114.88	114.69	70.12	81.64
6.04.2020	76	114.31	108.38	108	70.12	88.29
7.04.2020	153	141.82	132.51	140.56	153	149.55
8.04.2020	91	118.05	120.9	121.72	104.71	99.07
9.04.2020	132	132.36	122.85	127.36	131.6	122.98
11.04.2020	124	128.07	131.37	138.17	104.71	128.9
12.04.2020	158	147.09	143.09	147.63	158.2	153.62
14.04.2020	72	111.41	102.26	80.46	70.12	77.71
15.04.2020	142	134.89	134.94	137.91	139.67	135.84

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
18.04.2020	153	141.05	130.19	137.69	153	143.72
19.04.2020	119	127.8	122.58	126.75	104.71	124.53
21.04.2020	175	174.36	166.07	172.69	175.33	180.49
22.04.2020	174	173.6	165.41	170.97	173.57	175.11
25.04.2020	137	132.19	137.81	140.48	139.67	133.76
26.04.2020	176	174.66	174.16	174.66	176.86	174.98
28.04.2020	124	129.29	115.65	119.9	122.2	118.31
29.04.2020	162	154.11	146.24	151.33	163	156.84
30.04.2020	163	153.64	152.58	154.82	162.86	157.68
2.05.2020	169	164.81	148.26	164.6	169.63	164.18
3.05.2020	160	150.65	147.76	151.87	161.67	156.49
4.05.2020	102	121.31	123.87	124.75	104.71	111.23
5.05.2020	152	139.99	135.22	140.63	152.5	138.98
6.05.2020	151	138.28	137.88	146.6	152.5	148.85
7.05.2020	137	131.6	140.49	141.92	139.67	136.97
9.05.2020	153	138.7	141.56	147.4	152.5	149.81
10.05.2020	170	167	163.05	165.5	169.43	169.69
11.05.2020	137	132.06	134.18	141.03	139.67	133.5
12.05.2020	134	131.14	131.44	133.89	131.6	132.19
13.05.2020	80	114.25	107.04	104.53	70.12	94.79
17.05.2020	147	137.56	123.87	119.96	152.5	110.46
18.05.2020	84	115.53	111.92	113.27	70.12	96.86
19.05.2020	158	149.33	138.64	145.89	158.2	156.57

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
20.05.2020	167	164.09	142.9	154.35	169.63	166.93
30.05.2020	175	173.87	162.78	174.82	175.33	174.57
31.05.2020	174	173.19	163.21	172.47	173.57	174.09
1.06.2020	137	133.19	141.37	144.42	139.67	157.6
2.06.2020	176	176.77	174.43	175.44	176.86	176.26
3.06.2020	190	198.7	205.17	192.48	189.43	199.74
4.06.2020	185	191.11	186.53	189	186.6	185.45
7.06.2020	164	158.56	166.37	163.3	164.22	164.37
8.06.2020	167	161.29	170.71	164.76	167.44	164.43
10.06.2020	164	157.88	155.55	159.55	164.22	160.55
11.06.2020	176	174.8	176.18	174.74	175.33	175.87
14.06.2020	158	147.69	159.23	156.81	163	155.38
15.06.2020	164	156.83	156.22	161.43	164.22	163.59
16.06.2020	167	163.11	152.67	162.47	167.44	166.86
17.06.2020	164	157.59	155.21	161.54	164.22	163.3
18.06.2020	185	190.02	188.01	186.63	186.6	186.7
20.06.2020	190	196.28	196.54	189.13	189.43	195.01
21.06.2020	192	197.9	199.54	187.93	192.6	195.99
22.06.2020	197	205.11	211.81	193.04	272.75	199.94
23.06.2020	169	164.55	177.2	168.23	169.43	164.39
24.06.2020	203	214.63	211.51	206.97	202.71	206.97
25.06.2020	189	194.55	193.65	189.7	189.43	191.32
27.06.2020	270	268.94	254.44	265.44	260.33	265.44

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
28.06.2020	226	234.44	216.73	229.49	222.5	227.12
29.06.2020	178	179.32	180.42	180.1	176.86	175.57
30.06.2020	162	154.73	168.52	157.53	163	159.88
1.07.2020	175	171.88	165.9	174.86	175.33	175.38
2.07.2020	167	162.06	148.84	163.22	167.44	166.91
4.07.2020	183	185.62	180.3	185.58	186.6	183.7
5.07.2020	176	173.3	173.05	178.12	175.33	175.8
6.07.2020	157	144.48	150.7	159.92	156.6	156.2
7.07.2020	194	200.8	189.87	200.57	192.6	195.49
8.07.2020	185	187.69	179.67	188.96	186.6	185.05
9.07.2020	169	163.46	160.97	170.17	169.43	168.68
11.07.2020	274	270.08	261.19	269.97	274	269.24
12.07.2020	168	162.8	156.08	165.76	167.44	169.01
13.07.2020	153	139.75	130.86	132.15	153	151.6
14.07.2020	190	196.09	177.25	196.69	189.43	192.35
15.07.2020	236	238.73	223.71	239.4	233.89	237.46
16.07.2020	151	135.07	141.64	146.91	152.5	149.31
18.07.2020	194	200.63	189.86	201.84	192.6	196.63
19.07.2020	168	163.15	147.91	166.67	167.44	168.64
20.07.2020	167	161.81	152.25	168.33	192.5	168.61
21.07.2020	170	165.7	160.76	172.31	169.43	169.81
22.07.2020	193	199.49	193.67	197.64	192.6	194.49
23.07.2020	179	176.74	183.77	176.57	179.33	178.51

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
25.07.2020	185	184.64	175.47	187.27	184.4	185.82
26.07.2020	195	199.96	184.27	204.92	192.6	207.92
27.07.2020	174	169.97	166.76	175.32	173.57	173.77
28.07.2020	176	173.1	172.58	175.76	176.86	175.98
3.08.2020	165	155.23	164.01	161.22	162.86	165.62
4.08.2020	169	164.36	172.03	174.35	169.43	170.19
5.08.2020	221	227.35	216.49	224.5	222.5	219.72
6.08.2020	175	170.25	168.18	175.91	175.33	174.31
10.08.2020	199	206.93	199.19	205.11	198.57	200.75
11.08.2020	199	207.4	201.32	203.42	198.57	201.01
12.08.2020	222	226.39	222.59	215.61	222.5	221.26
13.08.2020	199	208.3	204.77	203.46	198.57	200.8
15.08.2020	190	193.83	199.52	189.04	189.43	191.09
16.08.2020	230	232.53	225.34	224.71	233.89	228.26
17.08.2020	164	151.85	164.33	162.13	162.86	161.37
19.08.2020	195	202.28	191.9	201.94	192.6	198.83
20.08.2020	164	154.49	145.26	157.73	164.22	162.2
22.08.2020	170	163.09	158.3	169.53	169.43	171.86
23.08.2020	169	161.23	156.57	168.49	169.43	170.15
24.08.2020	164	153.58	151.03	160.47	164.22	163.48
29.08.2020	163	153.01	148.18	155.38	163	163.04
31.08.2020	164	157.25	138.82	159.53	164.22	162.13
1.09.2020	122	126.07	126.6	129.71	122.2	125.43

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
3.09.2020	160	147.89	141.5	153.04	162.86	156.85
5.09.2020	285	277.03	265.81	280.79	294.86	281.99
6.09.2020	168	161.77	160.55	167.02	167.44	166.93
7.09.2020	167	158.55	167.22	167.25	167.44	166.27
9.09.2020	179	178.1	170.88	179.06	179.33	179.62
10.09.2020	197	205.28	198.79	202.4	272.75	197.86
12.09.2020	227	230.77	224.9	223.34	222.5	225.98
13.09.2020	190	195.38	189.25	192.58	189.43	191.03
14.09.2020	169	161.81	161.6	166.02	169.43	167.7
15.09.2020	186	187.92	180.17	189.11	184.4	191.81
16.09.2020	199	209.04	198.73	208.1	198.57	210.51
17.09.2020	220	226.66	218.26	219.29	222.5	218.54
19.09.2020	247	248.25	246.02	242.46	244.13	245.04
20.09.2020	208	217.22	222.9	205.67	208.8	209.07
21.09.2020	192	199.19	203.13	192.64	192.6	192.89
22.09.2020	209	218.59	218.27	210.14	208.8	209.52
23.09.2020	197	207.44	199.11	202.27	272.75	197.91
24.09.2020	269	265.85	263.81	263.48	260.33	263.08
26.09.2020	177	176.2	163.22	176.02	176.86	177
27.09.2020	187	192.59	179.83	189.49	186.6	190.58
28.09.2020	174	172.38	162.64	170.02	173.57	169.36
29.09.2020	188	194.36	178.19	190.1	189.43	187.89
30.09.2020	293	287.06	267.2	297.66	294.86	288.63

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
1.10.2020	194	203.83	203.4	197.11	192.6	233.39
3.10.2020	209	220.1	218.42	211.57	208.8	211.76
4.10.2020	203	215.39	214.28	208.13	202.71	205.28
5.10.2020	199	211.62	210.07	203.97	198.57	225.39
6.10.2020	243	247.91	238.31	240.74	244.13	251.72
7.10.2020	193	201.47	202.96	195.66	194	196.38
8.10.2020	206	217.31	220.8	209.63	206.4	208.89
10.10.2020	170	168.41	171.43	168.28	169.43	171.09
11.10.2020	225	233.95	225.98	225.83	222.5	277.08
12.10.2020	201	215.83	209.86	209.15	202.71	209.77
13.10.2020	185	191.78	195.95	186.73	184.4	194.71
14.10.2020	197	209.5	208.61	202.25	198.57	201.5
15.10.2020	241	246.26	245.09	239.04	244.13	240.88
17.10.2020	185	190.97	193.97	186.2	184.4	188.83
18.10.2020	195	206.91	206.24	199.23	194	194.74
19.10.2020	271	270.55	266.2	264.64	274	271.38
20.10.2020	222	231.48	228.76	222.66	222.5	226.58
21.10.2020	243	248.72	241.38	241.1	244.13	242.38
22.10.2020	313	304.11	305.21	307.87	312.44	310.98
24.10.2020	179	183.86	183.61	178.67	179.33	181.81
25.10.2020	216	227.84	230.18	218.6	214	215.84
26.10.2020	319	309.48	314.5	318.21	312.44	319.05
27.10.2020	279	276.84	282.2	274.87	280.75	277.15

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
28.10.2020	195	207.58	208.11	199.03	194	195.74
31.10.2020	312	303.24	327.14	314.59	312.44	311.22
1.11.2020	269	270.08	283.38	269.34	260.33	272.38
2.11.2020	196	208.81	221.83	203.68	194	201.99
3.11.2020	218	229.54	224.77	216.92	222.5	221.94
7.11.2020	376	354.4	377.09	383.06	376.75	372.6
8.11.2020	273	273.79	291.28	269.65	274	289.3
9.11.2020	264	265.16	269.64	259.92	260.33	260.38
10.11.2020	199	213.49	219.1	204.6	198.57	203.21
11.11.2020	258	260.47	269.47	253.37	260.33	259.15
12.11.2020	235	241.98	246.5	232.18	233.89	234.59
14.11.2020	84	106.13	126.22	82.73	203.5	99.95
15.11.2020	193	206.54	194.32	211.95	194	196.31
16.11.2020	180	185.88	194.62	188.68	183.83	194.57
17.11.2020	184	192.52	184.03	188.52	184.4	188.65
18.11.2020	214	227.95	214.29	221.46	214	218.2
21.11.2020	119	130.94	131.49	144.4	115.43	127.43
22.11.2020	155	148.74	140.55	148.61	156.29	145.63
23.11.2020	262	265.43	257.74	278.35	273	256.15
24.11.2020	132	134.47	139.97	139.29	131.6	137.31
25.11.2020	183	190.27	180.33	195.1	179.33	183.38
26.11.2020	206	220.79	224.98	228.76	206.4	214.9
28.11.2020	273	273.26	286.7	272.79	274	277.54

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
29.11.2020	251	255.22	262.63	251.98	244.13	249.8
30.11.2020	325	313.42	321.89	313.04	312.44	306.36
1.12.2020	272	271.24	277.33	267.71	274	266.43
2.12.2020	310	302.04	311.77	299.38	312.44	299.44
3.12.2020	238	244.59	242.53	240.3	233.89	235.25
4.12.2020	160	153.59	135.24	148.58	161.67	163.84
5.12.2020	204	218.31	216.32	211.43	202.71	207.03
6.12.2020	231	239.44	247.83	236.53	233.89	237.68
7.12.2020	152	125.89	134.93	145.36	139	150.8
8.12.2020	130	132.27	132.3	134.28	139	129.32
9.12.2020	346	332.13	344.43	340.52	345.62	330.17
10.12.2020	272	273.52	278.28	276.2	274	270.6
11.12.2020	173	174.97	157.47	168.26	173.57	174.11
12.12.2020	295	293.27	300.86	295.13	294.86	297.47
13.12.2020	162	158.92	141.88	156.42	161.67	165.42
14.12.2020	236	187.52	175.66	183.74	210	214.76
15.12.2020	243	252.48	263.57	247.89	373.75	255.96
16.12.2020	281	283.17	391.87	280.67	373.75	370.6
17.12.2020	411	389.34	439	418.79	436.75	412.73
18.12.2020	346	333.07	358.97	341.38	345.62	346.46
19.12.2020	265	268.38	285.13	271.87	273	282.87
20.12.2020	301	296.71	310.35	296.03	294.86	303.41
21.12.2020	191	202.48	193.54	203.54	194	193.5

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
22.12.2020	181	187.88	178.98	187.3	183.83	180.84
23.12.2020	291	289.1	295.73	287.31	294.86	290.62
24.12.2020	345	332.19	350.18	340.51	345.62	343.64
25.12.2020	211	225.46	217.1	219.5	208.8	215.07
26.12.2020	179	185.39	183.69	188.14	176.86	180.53
27.12.2020	198	216.62	214.35	214.16	258.75	216.22
28.12.2020	154	147.96	151.83	152.58	156.6	154.18
29.12.2020	238	248.23	243.52	237.61	258.75	240.4
30.12.2020	374	355.97	382.58	374.67	376.75	371.1
31.12.2020	316	309.75	337.82	311.55	312.44	320.88
1.01.2021	293	291.82	301.01	288.61	373.75	297.02
2.01.2021	277	278.6	280.95	272.55	274	278.14
3.01.2021	201	200.25	193.79	194.5	194	197.79
4.01.2021	168	167.28	157.52	167.9	169.63	169.44
5.01.2021	193	183.55	173.66	184.51	183.83	185.37
6.01.2021	255	260.58	259.97	256.42	273	251.69
7.01.2021	193	192.54	183.25	189.71	186.6	199.75
8.01.2021	187	197.77	189.79	195.66	210	190.18
9.01.2021	258	264.1	261.83	255.82	373.75	259.69
10.01.2021	173	176.05	172.68	174.57	173.57	181.22
11.01.2021	306	301.68	310.74	300.87	312.44	307.78
12.01.2021	181	187.22	183.4	179.55	194.75	184.81
13.01.2021	229	239.77	230.43	225.9	233.89	229.5

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
14.01.2021	341	328.56	338.59	337.97	345.62	340.28
15.01.2021	334	322.88	333.38	329.71	345.62	332.87
16.01.2021	279	278.79	275	275.5	280.75	276.01
17.01.2021	264	266.9	260.21	260.95	273	260.37
18.01.2021	242	249.28	247.65	243	244.13	240.04
19.01.2021	223	234.36	229.23	227.39	222.5	222.71
20.01.2021	202	217.69	226.43	208.55	202.71	225.99
21.01.2021	341	328.79	339.43	338.77	345.62	340.5
22.01.2021	165	163.98	161.15	160.59	163	171.42
23.01.2021	422	404.5	450.78	473.04	436.75	379.21
24.01.2021	314	307.94	312.72	308.79	312.44	313.34
25.01.2021	219	231.74	229.75	223.36	222.5	223.58
26.01.2021	210	224.66	221.82	215.33	208.8	215.2
27.01.2021	377	358.15	378.92	382.48	376.75	374.38
28.01.2021	244	251.76	249.52	241.92	244.13	244.41
29.01.2021	224	235.63	233.1	225.32	222.5	225.8
30.01.2021	241	248.74	245.74	237.83	244.13	239.53
31.01.2021	322	313.62	319.07	317.57	312.44	320.92
1.02.2021	229	238.93	247.77	233.29	233.89	238.61
2.02.2021	168	166.93	164.17	168.62	169.63	166.83
3.02.2021	159	153.42	144.37	154.24	158.2	157.74
4.02.2021	170	171.43	162.39	168.21	169.63	169.96
5.02.2021	186	195.42	191.88	186.84	194.75	189.48

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
6.02.2021	203	217.31	219.98	209.31	202.71	207.49
7.02.2021	182	186.84	190.81	182.5	183.83	183.4
8.02.2021	189	197.6	197.7	191.77	194	188.33
9.02.2021	177	164.5	169.18	166.47	176.5	173.95
10.02.2021	214	225.83	227.22	212.95	214	215.33
11.02.2021	205	186.05	191.87	182.12	194.75	199.36
12.02.2021	207	132.61	151.98	158.18	157.71	188.69
13.02.2021	203	216.98	218.17	207.04	202.71	204.85
15.02.2021	202	175.76	175.01	178.61	173.57	179.47
16.02.2021	207	177.7	191.09	181.06	194.75	204.04
17.02.2021	212	161.83	175.93	168.71	192.5	199.38
18.02.2021	187	181.74	198.47	184.67	183.83	191.25
19.02.2021	204	216.89	224.58	208.38	202.71	207.16
20.02.2021	169	165.91	173.93	167.26	169.63	167.75
21.02.2021	183	151.97	145.37	148.91	161.67	142.93
22.02.2021	109	125.17	118.2	121	104.71	106.9
23.02.2021	180	132.99	125.9	133.14	157.71	159.94
24.02.2021	157	149.71	141.66	151.3	156.6	154.88
25.02.2021	127	125.98	117.94	122.51	115.43	132.01
26.02.2021	395	371.42	426.94	391.6	436.75	387.97
27.02.2021	161	157.17	147.78	157.98	162.86	158.11
28.02.2021	170	169.64	168.47	174.31	176.5	173.95
2.03.2021	151	139.63	150.31	149.92	157.71	151.44

Tarih	Ölçülen HKİ	Lineer Reg.	YSA	DVM	Karar Ağ.	GSR
3.03.2021	122	130.4	131.89	141.68	115.43	127.14
4.03.2021	162	155.61	166.88	160.81	162.86	167.84
5.03.2021	142	135.2	156.9	155.07	157.71	153.19
6.03.2021	114	113.01	109.95	107.58	203.5	109.66
7.03.2021	156	146.92	132.56	139.74	156.29	148.46
8.03.2021	156	147.17	145.6	148.71	156.29	150.12
9.03.2021	119	129.2	127.99	130.03	115.43	115.15
11.03.2021	114	125.13	114.73	109.79	104.71	114.15
13.03.2021	109	125.65	111	113.44	104.71	110.14
15.03.2021	213	224.22	215.37	224.57	214	212.49
16.03.2021	180	183.99	172.33	178.63	179.33	181.65

ÖZ GEÇMİŞ

Sakhidad Faizi tarihinde’ın şehrinde doğdu. İlk, orta ve lise öğrenimini Cavzcan’da tamamladı. 2012 yılında girdiği Cavzcan Üniversitesi Kimya Teknolojisi Mühendisliği Bölümü’nden 2016’da mezun oldu. 2018’de Niğde Ömer Halisdemir Üniversitesi’nde Tömer’de Türkçe eğitimi aldı. 2019-2020 Eğitim-Öğretim Yılı Güz Yarıyılında Niğde Ömer Halisdemir Üniversitesi Çevre Mühendisliği ABD’nda uluslararası öğrenci olarak yüksek lisans öğrenimine başladı. O tarihten itibaren yüksek lisans öğrenimini devam ettirmektedir.

