



## Hava Kirliliğinin Makine Öğrenmesi Tabanlı Tahmini: Başakşehir Örneği

### Prediction of Air Pollution based on Machine Learning Methods: A Case Study for Başakşehir, İstanbul

<sup>1</sup>Sibel ÜNALDI , <sup>2</sup>Nesibe YALÇIN 

<sup>1</sup>Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, 11230, Bilecik, Türkiye

<sup>2</sup>Erciyes Üniversitesi, Mühendislik Fakültesi, 38280, Kayseri, Türkiye

<sup>1</sup>sibelunaldi@bilecik.edu.tr, <sup>2</sup>nesibeyalcin@erciyes.edu.tr

Araştırma Makalesi/Research Article

#### ARTICLE INFO

##### Article history

Received : 10 January 2022

Accepted : 28 February 2022

##### Keywords:

Air pollution, Artificial Neural Networks, Machine Learning, Multiple Linear Regression, Random Forest

#### ABSTRACT

Regular measurement and monitoring of pollutant parameters, prediction of air pollution, and early assessment of its effects on human health are very important to provide a healthier living environment for the city's residents, and to minimize exposure to air pollution. This study aims to predict air pollution by using machine learning methods. The daily average concentrations of various air pollutants, as well as wind direction, wind speed and air pressure values measured between 2016 and 2021 in Başakşehir are used. PM10, CO, SO<sub>2</sub>, NO<sub>2</sub>, and O<sub>3</sub> concentrations are predicted using Multiple Linear Regression, Support Vector Machine, K Nearest Neighbor, Decision Tree, Random Forest, and Multi-layer Perceptron Neural Network methods. The obtained results are compared in terms of some performance metrics. The Random Forest method has the minimum error values in the prediction of PM10, CO, SO<sub>2</sub>, and O<sub>3</sub> concentrations, and Multiple Linear Regression shows the better prediction performance for NO<sub>2</sub> concentration.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

#### MAKALE BİLGİSİ

##### Makale Tarihleri

Gönderim : 10 Ocak 2022

Kabul : 28 Şubat 2022

##### Anahtar Kelimeler:

Çoklu Doğrusal Regresyon, Hava kirliliği, Makine Öğrenmesi, Rastgele Orman, Yapay Sinir Ağları

#### ÖZET

Şehir sakinleri için daha sağlıklı bir yaşam ortamının sağlanması ve onların hava kirliliğine maruziyetinin en aza indirilmesi oldukça önemlidir. Bunun için yapılabilecek çalışmalar arasında kirletici parametrelerine ilişkin ölçümlerin düzenli olarak yapılması ve izlenmesi, hava kirliliğinin tahmin edilmesi ve insan sağlığı üzerindeki etkilerinin erken değerlendirilmesi yer almaktadır. Bu çalışmada, makine öğrenmesi yöntemleri kullanılarak hava kirliliği tahmini gerçekleştirilmiştir. İstanbul ili Başakşehir ilçesinde 2016-2021 yılları arasında ölçülen çeşitli hava kirleticilerine ilişkin günlük ortalama konsantrasyonları ile rüzgar yönü, rüzgar hızı ve hava basıncı değerleri kullanılmıştır. PM10, CO, SO<sub>2</sub>, O<sub>2</sub> ve O<sub>3</sub> kirleticilerin konsantrasyonları, Çoklu Doğrusal Regresyon, Destek Vektör Makinaları, K En Yakın Komşu, Karar Ağaçları, Rastgele Orman ve Çok Katmanlı Algılayıcı Sinir Ağı yöntemleri ile tahmin edilmiştir. Elde edilen sonuçlar karşılaştırıldığında PM10, CO, SO<sub>2</sub> ve O<sub>3</sub> konsantrasyonları tahmininde Rastgele Orman yöntemi, NO<sub>2</sub> tahmininde ise Çoklu Doğrusal Regresyon, en iyi sonuçları sunmuştur.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

## 1. GİRİŞ

Hava kirliliği, dünya çapında ölümler için dördüncü önde gelen risk faktörüdür ve bu nedenle insan sağlığına yönelik en büyük çevresel tehdit olarak kabul edilmiştir. Dünya nüfusunun yaklaşık %91'i, Dünya Sağlık Örgütü (World Health Organization, WHO) tarafından belirlenen hava kalitesi limitlerini aştığı yerlerde yaşamaktadır. Hava kirliliğine maruz kalmanın ciddi sağlık sonuçları vardır. WHO'ya göre kalp hastalığı, felç, akciğer kanseri ve kronik solunum yolu hastalıklarına bağlı olarak yılda tahmini 4,2 milyon ölüm hava kirliliği nedenidir [1]. Hava kirliliği, insan sağlığına zarar vermenin yanı sıra insan hayatını da olumsuz yönde etkilemektedir. Şiddetli hava kirliliği, atmosferin görünürlüğünü azaltarak trafik kazası olasılığını artırmakta ve pus oluşumuna neden olarak insanların normal seyahatlerini geciktirebilmektedir. Ayrıca ekosistemlerin yapısına çökeltmeler ile dâhil olarak toprağın yapısını değiştirmektedir [2]. Hava kirliliğinin bir başka olumsuz etkisi ise üzerinde biriken partikül maddeler nedeniyle güneş enerjisi sistemlerinin enerji üretim verimini düşürmesidir [3].

Hava kirliliği, iklim değişikliğine katkıda bulunan önemli bir faktördür ve hem gelişmiş hem de gelişmekte olan ülkeleri etkilemektedir. Endüstriyel faaliyetler, trafik yoğunluğu gibi nedenlerle şehirlerde her geçen gün hava kirliliği artmakta, hava kalitesi bozulmakta ve dolayısıyla bu durum sağlık ve iklim için büyük bir tehdit oluşturmaktadır. Şehirlerde çeşitli noktalarda, hava kalitesinin izlenmesi amaçlı hava kalitesi izleme istasyonları bulunmaktadır. Bu istasyonların kurulması yüksek maliyetlidir ve sonrasında pahalı bakım gerektirebilmektedir [4]. Bu nedenle, hava kirliliği tahmin çalışmalarının önemi artmıştır. Hava kirliliğinin tahminine yönelik literatürde yer alan çalışmalarda, makine öğrenmesi [4-9], derin öğrenme [10-12] ve veri madenciliği [13,14] algoritmaları kullanılmış ve boyutu 2,5 µm ile 10 µm arasında olan partikül madde (PM<sub>10</sub>), azot monoksit (NO), kükürt dioksit (SO<sub>2</sub>) gibi önemli hava kirlenmelerinin konsantrasyonları üzerinden başarılı tahmin sonuçları elde edilmiştir. [7]'de Adana ili için azot dioksit (NO<sub>2</sub>), SO<sub>2</sub>, ozon (O<sub>3</sub>), karbon monoksit (CO) ve PM<sub>10</sub> gibi hava kirlenmelerinin ölçüm verileri ele alınmış ve çeşitli makine öğrenmesi algoritmaları ile hava kalite indeksi elde edilmiştir. Erzincan ili için yapılan hava kirlilik tahmin çalışmasında [9], PM<sub>10</sub> ve SO<sub>2</sub> kirlenmelerinin 2016-2018 yılları arasındaki günlük kayıtları kullanılmış ve makine öğrenmesi yöntemlerinden KNN ile tahmin gerçekleştirilmiştir İç Anadolu Bölgesi ve çevresine ait ölçüm verilerinin ele alındığı çalışmada [11], uzun-kısa süreli bellek (Long - Short Term Memory, LSTM) ağı ve klasik derin öğrenme yöntemi kullanılarak PM<sub>10</sub> için tahmin çalışması yapılmıştır. [10]'da ise hava kalitesi tahmini için derin öğrenme ve görüntü tabanlı bir model önerilmiştir. Ayrıca, çalışma kapsamında derlenen yüksek kaliteli bir dış hava kalitesi veri seti NWN- AQI üzerinde AQC-Net, Destek Vektör Makinesi (Support Vector Machine, SVM) ve Derin Kalıntı Ağı (ResNet) karşılaştırılmış ve AQC-Net'in hava kalitesi sınıflandırması için diğer yöntemlere kıyasla daha doğru sonuçlar verdiğini belirtilmiştir. Milano'nun kentsel bölgesindeki hava kalitesi tahminine yönelik önerilen çalışmada [8], farklı makine öğrenimi yaklaşımları kullanılmış, meteorolojik ve toplu taşımayla ilgili özellikler ele alınmıştır. [15] çalışması ise hava kalitesinin iyileştirilmesi için hangi parametreler ve hangi yöntemler kullanılarak nasıl bir analiz ile incelenmesine yönelik bir fikir sunmaktadır.

Hava kirliliği ve sağlık problemleri (özellikle kronik hastalıklar) arasındaki ilişkiyi gösteren çok sayıda çalışma vardır. [16]'da WHO kılavuz değerlerinin [17] altındaki düşük kirlilik seviyelerinde bile dış hava kirliliğinin ölüm oranıyla ilişkili olduğuna dair kanıtlar sunulmuş ve boyutu 2,5 µm' den küçük olan partikül madde (PM<sub>2,5</sub>), NO<sub>2</sub> ve siyah karbona daha fazla maruz kalma, önemli ölçüde artan ölüm riski ile ilişkilendirilmiştir. Azot oksitler (NO<sub>x</sub>) olarak adlandırılan azot oksitler 6 farklı gaz (NO, NO<sub>2</sub>, diazot oksit (N<sub>2</sub>O), diazot trioksit (N<sub>2</sub>O<sub>3</sub>), diazot tetraoksit (N<sub>2</sub>O<sub>4</sub>) ve diazot pentaoksit (N<sub>2</sub>O<sub>5</sub>)) karışımından oluşmaktadır. NO ve NO<sub>2</sub> önemli hava kirlenmelerini oluşturur ve atmosferde kalış süreleri yaklaşık 2-5 gün arasında değişmektedir [18]. NO<sub>x</sub>'ler, troposferde O<sub>3</sub> oluşumuna ve atmosferde nitrik asit oluşturarak asit yağmurlarına neden oldukları için dikkat edilmesi gereken önemli hava kirlenmelerindendir [15, 19]. Ayrıca, yüksek konsantrasyonlarda NO<sub>2</sub> gazı bulunması ciddi düzeyde solunum yolu tahribatına yol açabilmektedir. Bu nedenle, NO<sub>x</sub>' in insan sağlığına zarar vermeyecek şekilde dönüşümleri yapılarak giderilmesi gerekmektedir [15]. Hava kalitesinin sürekli olarak izlenmesi ve kirlilik seviyesinin tahmin edilmesi, gerek hava kalitesini kabul edilebilir seviyede tutmak gerekse hava kirlenmelerinin kronik solunum yolu hastalıkları gibi sağlığa olumsuz etkilerini azaltmak için hava kirliliğine yönelik önleyici tedbirlerin alınabilmesi oldukça önemlidir.

Hava kalitesinin iyileştirilmesi, hava kirliliğinin neden olduğu potansiyel sağlık etkilerinin azaltılması, iklim değişikliği ile mücadelenin sürdürülebilmesi gibi amaçlarla hava kalitesi/kirliliği tahmin çalışmalarına olan ihtiyaç her geçen gün artmaktadır. Bu çalışmada, hava kirliliğini analiz etmek ve tahmin etmek için Çoklu Doğrusal Regresyon (Multiple Linear Regression, MLR), SVM, K En Yakın Komşu (K Nearest Neighbor, KNN), Karar Ağacı, Rastgele Orman ve Çok Katmanlı Algılayıcı Sinir Ağı (Multi-Layer Perceptron Neural Network, MLPNN) makine öğrenmesi yöntemleri kullanılmıştır. Günlük ortalama PM<sub>10</sub>, CO, SO<sub>2</sub>, NO<sub>2</sub> ve O<sub>3</sub> konsantrasyonları hava kirliliği parametreleri olarak ele alınmış ve tahmin sonuçları en yüksek öngörüye sahip yöntemlerin belirlenmesi için çeşitli değerlendirme metrikleri kullanılarak karşılaştırılmıştır.

Bu çalışmanın ilk bölümünde, hava kirliliği konusuna giriş yapılmış ve makine öğrenmesi yöntemleri kullanılarak hava kirliliğinin tahminine ilişkin literatür araştırmasına yer verilmiştir. İkinci bölümde, kullanılan veri seti ve makine öğrenme yöntemleri detaylı olarak incelenmiş ve performans değerlendirme metrikleri hakkında bilgi verilmiştir. Araştırma sonuçları ve tartışma bölümünde, elde edilen uygulama sonuçları karşılaştırmalı olarak sunulmuş ve değerlendirilmiştir. Dördüncü bölümde ise çalışma yorumlanarak sonuçlandırılmıştır.

## 2. MATERYAL VE YÖNTEMLER

### 2.1. Veri Seti


Türkiye, Avrupa Birliği (AB) üyelik sürecinde bulunması nedeniyle mevzuatlarını AB ile uyumlu hale getirmek için hava kirleticilerinin sınır değerlerini kademeli olarak hedef değerlere getirmeyi planlamıştır [2]. Kirletici parametrelerinin uyumlu olması için istenen hedef sınır değerlerinin ülkemizde yürürlüğe girme tarihleri: CO için 1 Ocak 2017, PM<sub>10</sub> ve SO<sub>2</sub> için 1 Ocak 2019, O<sub>3</sub> için 1 Ocak 2022 ve NO<sub>2</sub> için de 1 Ocak 2024. En son olarak NO<sub>2</sub> için sınır değeri uyumlanacak ve 2024'ten itibaren tüm kirletici parametreler için Türkiye, AB mevzuatını uygulayacaktır. Tablo 1'de Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği [20] kirletici sınır değerleri (2022 yılı için Türkiye sınır değerleri) verilmektedir. Ayrıca bahsi geçen kirleticilerin dış ortam kaynakları [21] ve bu kirleticilere maruz kalma sonucu insan sağlığına etkileri [17,21,22] Tablo 1'de yer almaktadır.

**Tablo 1.** Hava kirleticileri, sınır değerleri [20], kaynakları [21] ve sağlığa etkileri [17,21,22].

Kirletici	Hava kalite seviyesi (µg/m <sup>3</sup> )	Kaynakları	Sağlığa Etkileri
PM <sub>10</sub>	50 (24 saatlik)	Sanayi, yakıt yanması, tarım ve ikincil kimyasal reaksiyonlar	KOAH, akut alt solunum yolu enfeksiyonları, kalp hastalıkları, akciğer kanseri, kardiyovasküler mortalite, solunum mortalitesi
SO <sub>2</sub>	125 (24 saatlik)	Fosil yakıt yanması	Astımla ilgili hastane başvuruları ve acil servis ziyaretleri, solunum mortalitesi
CO	10.000 (8 saatlik)	Eksik yanma ürünü, taşıt emisyonları	İskemik kalp hastalığı ile ilgili hastane başvuruları ve acil servis ziyaretleri
NO <sub>2</sub>	40+4 (saatlik) 200+20 (yıllık)	Taşıt emisyonları, yüksek sıcaklıkta yakma prosesleri	Astımla ilgili hastane başvuruları ve acil servis ziyaretleri, solunum mortalitesi
NO <sub>x</sub>	30 (yıllık)	Taşıt emisyonları, yüksek sıcaklıkta yakma prosesleri	Göz ve solunum yolu hastalıkları, asit yağmurları
O <sub>3</sub>	120 (8 saatlik)	Trafikten kaynaklanan azot oksitler ve uçucu organik bileşiklerin Güneş ışığıyla değişimi	Solunum sistemi problemleri, solunum mortalitesi, göz ve burunda iritasyon, astım, vücut direncinde azalma

Hava kirliliği tahmin çalışması için sanayi-kentsel bölge olarak tanımlanan İstanbul ili Başakşehir ilçesi seçilmiştir. Ayrıca ilçedeki hava kalitesi ölçüm istasyonu karayoluna yakın yerde (34 m) konumlandırılmıştır. Çalışmada kullanılan hava kalitesi ölçüm verileri, İstanbul Büyükşehir Belediyesi Çevre Koruma ve Kontrol Daire Başkanlığı Çevre Koruma Müdürlüğü Hava Kalitesi İzleme Merkezi'nden temin edilmiştir. Kullanılan veri seti, 2016-2021 periyodunu kapsayan 6 yıllık PM<sub>10</sub>, CO, SO<sub>2</sub>, NO, NO<sub>2</sub>, NO<sub>x</sub> ve O<sub>3</sub> kirleticileri ölçümlerine ilişkin günlük (24 saat) ortalama konsantrasyonları (µg/m<sup>3</sup>) ile rüzgar yönü (°), rüzgar hızı (km/h) ve hava basıncı (mbar) (toplamda 10 farklı özellik) değerlerini içermektedir. Başakşehir ilçesine ilişkin hava kirleticilerinin yıl bazlı ölçüm ortalamaları grafiği [23], Şekil 1'de sunulmuştur. Grafikte en dikkat çekici olan son iki yılda CO ve SO<sub>2</sub> konsantrasyonlarında gözlenen yüksek orandaki artıştır. Bununla birlikte O<sub>3</sub> miktarında da artış gözlenmiştir. COVID-19 pandemisi nedeniyle sokağa çıkma gibi kısıtlamaların daha çok uygulandığı 2019 ve 2020 yıllarında PM<sub>10</sub> ve NO<sub>2</sub> oranlarında düşüş görülse de 2021 yılında tekrar artışa geçmiştir.

Kirleticilerin istatistiksel özellikleri (minimum, maksimum, ortalama ve standart sapma) incelendiğinde 2020 COVID-19 pandemi sürecinde, diğer yıllara kıyasla maksimum NO, NO<sub>2</sub> ve NO<sub>x</sub> kirletici değerleri daha düşük ölçülmüştür. Ters şekilde CO ve SO<sub>2</sub> gazları için maksimum kirletici konsantrasyonu 2020 ve 2021 yıllarında elde edilmiştir ve bu yıllarda ortalama SO<sub>2</sub> konsantrasyonu, önceki yıllarda ölçülen en yüksek ortalamanın en az 3,4 katına çıkmıştır. PM<sub>10</sub> kirletici konsantrasyonu ortalama olarak sağlık açısından memnun edici aralıklarda olsa da kabul edilebilir seviyenin (50 µg/m<sup>3</sup>) üzerinde PM<sub>10</sub> ölçümleri mevcuttur. Son olarak, O<sub>3</sub> gazı için hesaplanan maksimum ve ortalama değerlerde 2020 ve 2021 yıllarında artış göstermiştir.



Şekil 1. Kirleticilere ilişkin yıl bazlı ölçüm ortalama değerleri [23].

## 2.2. Makine Öğrenmesi Yöntemleri

Hava kirliliği tahmin çalışmasında MLR, SVM, KNN, karar ağaçları, rastgele orman ve MLPNN makine öğrenmesi yöntemleri kullanılmıştır. Makine öğrenme yöntemlerine dayalı hava kirliliği tahmin modelleri, Python dilinde geliştirilmiştir. NumPy, SciPy, Scikit-Learn ve Matplotlib kütüphaneleri kullanılmıştır. Denemeler sonucunda, makine öğrenme yöntemleri için en iyi sonucu veren parametreler seçilmiştir.

### 2.2.1. MLR

Doğrusal bir regresyon modeli, sürekli/nicel değerli ilişkileri modellemek için kullanılır. Bağımsız değişken (girdi) ile bağımlı değişken (regresyon fonksiyonu, çıktı) arasında doğrusal bir ilişki olduğunu varsayar. Bağımsız değişken yardımı ile bağımlı değişkenin değeri tahmin edilir. Birden fazla bağımsız değişkenin girdi olarak yer aldığı MLR yöntemi, bağımsız değişkenlerin bireysel ve toplu olarak bağımlı değişkeni nasıl etkilediğine dair yeterli ve yorumlanabilir bir açıklama sunar [24]. Çalışmada MLR yöntemi ile konsantrasyonu tahmin edilmek istenen kirlenme parametresi ile veri setindeki diğer değişkenler arasındaki matematiksel ilişkiyi gösteren bir model üretilmiş ve bu model yardımı ile kirlenme konsantrasyonu tahmini yapılmıştır.

### 2.2.2. SVM

SVM, sınıflandırma ve regresyon (doğrusal ve doğrusal olmayan) analizi için kullanılan danışmanlı (supervised) bir makine öğrenmesi yöntemidir. Destek vektörleri yardımı ile optimal ayrılabilir sınıflar oluşturmak amacıyla yaygın olarak kullanılır. Maksimum marj kavramını kullanır ve çekirdek (kernel) en önemli özelliğidir. Çekirdek fonksiyonlarına bağlı olarak düşük boyutlu girdi alanı daha yüksek boyutlu alana dönüştürülür [25]. Çalışmada SVM algoritmasında, "linear" çekirdek fonksiyonu ile en iyi sonuç elde edilmiştir. Regresyon amaçlı kullanılan SVM, çekirdek parametresine ek olarak iki hiperparametre daha içermektedir: C düzenleme (regularization) parametresi ve  $\epsilon$  hata toleransı (error sensitivity) parametresi. Bu parametreler, eğitim verilerinin aşırı öğrenmesini önlemek için kullanılmaktadır [26]. Çalışmada, C sabiti 1 ve  $\epsilon$  0,1 seçilmiştir.

### 2.2.3. KNN

En basit makine öğrenmesi yöntemi olarak kabul edilen KNN, bellek tabanlıdır ve model oluşturmak için herhangi bir eğitim süreci gerektirmez. K adet en yakın (en benzer) komşu bilgisi üzerinden regresyon ve sınıflandırma işlemlerini gerçekleştirir. KNN algoritmasında, uzaklık ölçüğü olarak Öklid uzaklığı kullanılmıştır. Denemeler sonucunda en iyi sonucu veren en yakın komşu sayısı (K) ise 3 olarak belirlenmiştir.

### 2.2.4. Karar Ağaçları

Karar ağaçları, sınıflandırma ve regresyon problemlerinin çözümünde kullanılır. Ters ağaç görünümünde olup kök düğüm, dal ve yapraklardan oluşur. Kök düğüm daha fazla düğüme bölünebilir. Düğümlerde değişkenler, dallarda değişkenlerin aldığı değerler ve yapraklarda nihai sonuç temsil edilir. Kök düğümden yaprağa ulaşana dek ardışık düğümler takip edilerek karar alma işlemi gerçekleşir. Nihai sonucun sürekli değerler aldığı karar ağaçlarına regresyon ağaçları da denir.


### 2.2.5. Rastgele Orman

Rastgele orman yöntemi, danışmanlı bir makine öğrenme yöntemidir. Sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılmaktadır. Karar ağaçlarını temel alan bu yöntem, girdi parametreleri içinden rastgele seçtiği parametreler ile çok sayıda karar ağacı oluşturur [15], daha sonra karar ağaçlarının her birinden tahmin

alır ve oylama ile (sınıflandırma işlemi için) veya tahminlerin ortalamasını alarak (regresyon problemi için) en iyi sonucu üretir.

### 2.2.6. MLPNN

Yapay Sinir Ağları (YSA), insan beyninden esinlenerek geliştirilmiş bir makine öğrenmesi yöntemidir. Sinir hücrelerinin bağlantı şekline göre ileri ve geri beslemeli olarak sınıflandırılır. Ayrıca, öğrenme algoritmalarına göre danışmanlı, danışmansız (unsupervised) ve pekiştirmeli (reinforcement) öğrenmeye dayalı YSA çeşitleri bulunmaktadır. MLPNN, ileri beslemeli bir sinir ağı yapısındadır ve eğitim için danışmanlı bir öğretim algoritması olan geri yayılım (back-propagation) algoritmasını kullanır. Giriş, gizli (en az bir) ve çıkış katmanından oluşan MLPNN, ağırlık çıkışı ile istenen çıkış (hedef) arasındaki farkı minimuma getirmeyi amaçlar. Çalışma kapsamında, birçok deneme sonrası en iyi sonucu (minimum hatayı) veren MLPNN modeli, Şekil 2’de gösterildiği gibi elde edilmiştir. Modelde, 1 giriş katmanı, 2 gizli katman ve 1 çıkış katmanı yer almaktadır. Gizli katmanlarda ise sırasıyla 50 ve 10 sinir hücresi bulunmaktadır. Aktivasyon fonksiyonu olarak katmanlarda relu (rectified linear unit) fonksiyonu kullanılmıştır. Modelin eğitimi için kullanılan durdurma kriteri, 500 iterasyondur.



Şekil 2. Birden fazla gizli katman bulunan bir MLPNN mimarisi.

### 2.3. Performans Değerlendirme Metrikleri

Çalışma kapsamında elde edilen sonuçların değerlendirilmesinde kullanılan açıklayıcılık (belirtme) katsayısı  $R^2$ , Ortalama Mutlak Hata ( Mean Absolute Error, MAE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error, MAPE), Ortalama Karesel Hata (Mean Square Error, MSE) ve Kök Ortalama Karesel Hata (Root MSE, RMSE) metriklerine ilişkin formüller [27] sırasıyla Eşitlik 1, Eşitlik 2, Eşitlik 3, Eşitlik 4 ve Eşitlik 5’te verilmiştir;

$$R^2 = 1 - \frac{\sum_{i=1}^n (t_i - y_i)^2}{\sum_{i=1}^n (t_i - t_{ort})^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |t_i - y_i| \quad (2)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|t_i - y_i|}{t_i} \quad (3)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2 \quad (4)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2} \quad (5)$$

Burada  $n$  değeri, veri setinde kullanılan toplam örnek sayısını ve  $i = 1, 2, 3, \dots, n$  olmak üzere örnek indisini ifade etmektedir.  $i$ . örnek için istenen (gerçek, hedef) çıkış değeri  $t_i$  ve makine öğrenme yöntemi kullanılarak elde edilen (tahmin edilen) çıkış değeri ise  $y_i$ ’dir.  $t_{ort}$ , hedef çıkış değerlerinin ortalamasıdır.

### 3. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Ulusal Hava Kalitesi İndeksi, Çevre Koruma Kurumu (Environmental Protection Agency, EPA) Hava Kalitesi İndeksini ulusal mevzuatımız ve sınır değerlerimize uyarlayarak oluşturulmuştur. 5 temel kirlenici ( $PM_{10}$ , CO,  $SO_2$ ,  $NO_2$  ve  $O_3$ ) için hava kalitesi indeksi hesaplanmaktadır [21]. Bu nedenle çalışmada, belirtilen gösterge kirlenicileri üzerinden günlük ortalama hava kirliliği miktarının tahminlenmesi değerlendirilmiştir.



### 3.1. Araştırma Sonuçları

2016-2021 yılları arasındaki ölçüm değerlerinin yer aldığı veri setindeki eksik değer bulunan örnekler çıkarılmış ve toplamda 2.031 örnek elde edilmiştir. Veri setinin %75'i (1.523 örnek) eğitim, %25'i (508 örnek) test için ayrılmıştır. Veri setindeki bileşenler arasındaki korelasyon incelendiğinde, PM<sub>10</sub> ile NO ve NO<sub>x</sub>, CO ile SO<sub>2</sub>, NO ile NO<sub>x</sub>, NO<sub>2</sub> ile NO<sub>x</sub>, O<sub>3</sub> ile CO ve SO<sub>2</sub> kirleticileri arasında güçlü bir ilişki olduğu söylenebilir.

Çalışmada kullanılan makine öğrenme yöntemlerinin tahmin performansını değerlendirmek için R<sup>2</sup>, MAE, MSE, RMSE ve MAPE metrikleri kullanılmıştır. Kirletici konsantrasyonu tahmini için makine öğrenmesi yöntemleri kullanılarak elde edilen test sonuçları Tablo 2'de karşılaştırmalı olarak verilmiştir.

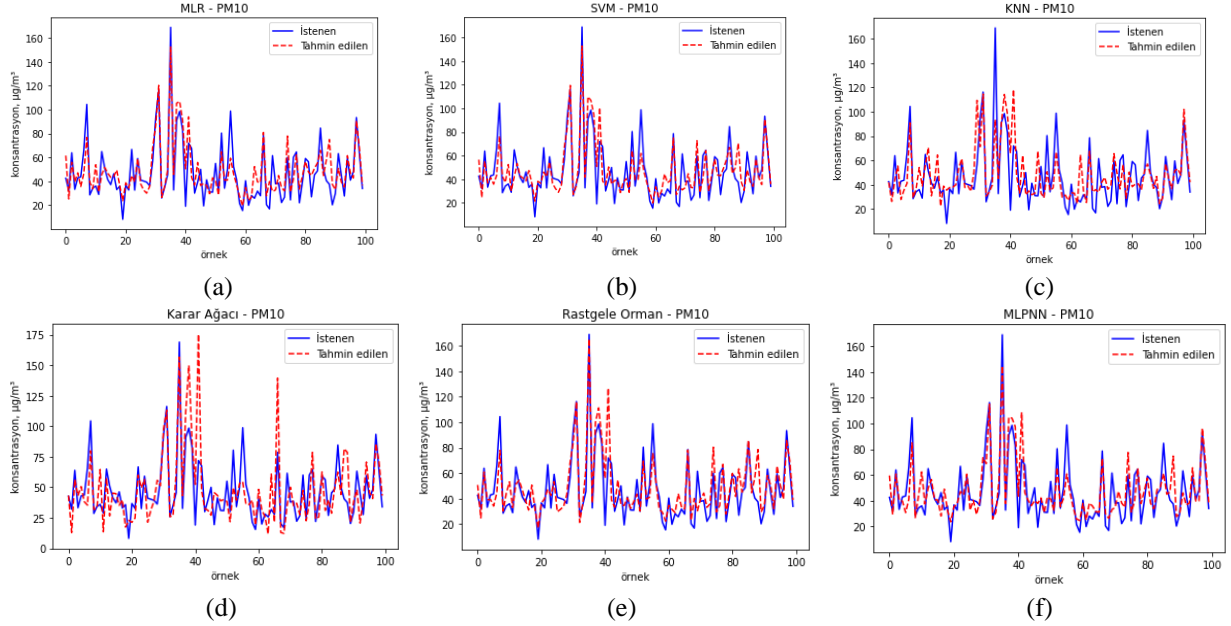
**Tablo 2.** Hava kirleticileri için elde edilen tahmin sonuçları.

Kirletici	Parametre	MLR	SVM	KNN	Karar Ağacı	Rastgele Orman	MLPNN
PM <sub>10</sub>	R <sup>2</sup>	0,66	0,67	0,51	0,38	<b>0,68</b>	0,64
	MAE	11,694	11,28	13,733	14,822	<b>10,996</b>	12,145
	MSE	259,639	258,546	376,003	475,333	<b>243,03</b>	275,197
	RMSE	16,113	16,079	19,391	21,802	<b>15,589</b>	16,589
	MAPE	0,3	0,276	0,356	0,348	<b>0,28</b>	0,314
SO <sub>2</sub>	R <sup>2</sup>	0,81	0,76	0,82	0,94	<b>0,96</b>	0,78
	MAE	5,679	5,347	4,648	3,021	<b>2,41</b>	5,472
	MSE	72,777	94,145	69,534	23,34	<b>13,77</b>	83,802
	RMSE	8,531	9,703	8,339	4,831	<b>3,71</b>	9,154
	MAPE	0,972	0,61	0,711	0,483	<b>0,418</b>	0,733
CO	R <sup>2</sup>	0,76	0,72	0,85	0,91	<b>0,97</b>	0,80
	MAE	508,733	474,899	306,129	194,429	<b>144,182</b>	426,276
	MSE	719.058,05	839.362,45	445.431,6	261.012,5	<b>89.035,92</b>	603.456,39
	RMSE	847,972	916,167	667,407	510,894	<b>298,388</b>	776,825
	MAPE	0,626	0,59	0,359	0,282	<b>0,2</b>	0,525
NO <sub>2</sub>	R <sup>2</sup>	<b>0,999</b>	0,995	0,73	0,96	0,97	0,98
	MAE	<b>0,237</b>	1,066	7,318	2,239	1,66	1,091
	MSE	<b>0,172</b>	2,131	121,29	18,636	14,906	7,517
	RMSE	<b>0,414</b>	1,46	11,013	4,317	3,861	2,742
	MAPE	<b>0,016</b>	0,144	0,527	0,139	0,128	0,187
O <sub>3</sub>	R <sup>2</sup>	0,61	0,61	0,52	0,57	<b>0,79</b>	0,61
	MAE	11,679	11,728	12,723	11,54	<b>8,444</b>	11,441
	MSE	210,333	214,069	263,456	232,067	<b>114,874</b>	212,389
	RMSE	14,503	14,631	16,231	15,234	<b>10,718</b>	14,574
	MAPE	0,246	0,253	0,256	0,223	<b>0,169</b>	0,244

Tabloda görüldüğü üzere, PM<sub>10</sub> tahmini için en iyi sonuçları, Rastgele Orman ve MLR yöntemi sunmuştur. Karar Ağacı ile PM<sub>10</sub> tahmininde en düşük R<sup>2</sup> değeri elde edilmiştir. SO<sub>2</sub> konsantrasyonu, Rastgele Orman ve Karar Ağacı yöntemi kullanılarak diğer yöntemlere kıyasla daha az hata ile tahmin edilmiştir. CO ve O<sub>3</sub> konsantrasyonları için elde edilen tahmin sonuçlarına göre Rastgele Orman yöntemi daha etkin bir performans göstermiş, tahminlerinde kullanılan parametreler tarafından daha yüksek bir oranda açıklanabilmiştir. Çalışmada NO<sub>2</sub> için en düşük hata ile tahmin gerçekleştirilmiş ve MLR yöntemi yüksek bir öngörü sağlamıştır. Ancak KNN, diğer makine öğrenmesi yöntemlerine kıyasla çok daha yüksek hata değerleri ile NO<sub>2</sub> konsantrasyonu tahmini gerçekleştirmiştir. Her bir kirletici konsantrasyonu tahmininde, her bir yöntem için aynı parametreler kullanılmıştır. Bu parametreler her bir kirletici tahmini için farklı seçilerek yöntemlerin daha düşük hata ile tahmin gerçekleştirmesi sağlanabilir. MLPNN yönteminde giriş parametreleri normalize edilerek tahmin başarısı artırılabilir. Ayrıca eğitim ve test işlemleri için ayrılan veri yüzdesi, yöntemlere göre tahmin başarısını etkilemektedir.

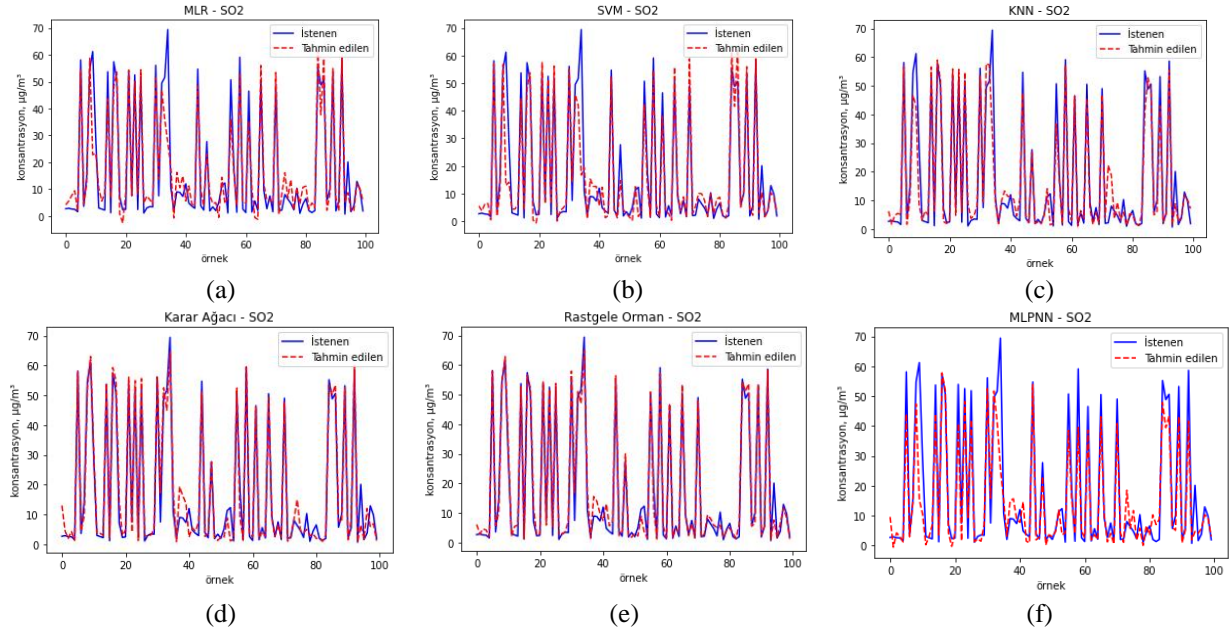
### 3.2. Tartışma

MLR, SVM, KNN, Karar Ağacı, Rastgele Orman ve MLPNN makine öğrenmesi yöntemleri kullanılarak elde edilen  $PM_{10}$  konsantrasyonu tahminine ilişkin kıyaslama grafikleri Şekil 3'te verilmiştir. Elde edilen tahmin sonuçları ve istenen değerler karşılaştırıldığında, MLR, SVM ve Rastgele Orman yöntemleri kullanılarak gerçekleştirilen tahminin, daha yüksek başarıma sahip olduğu görülmektedir.



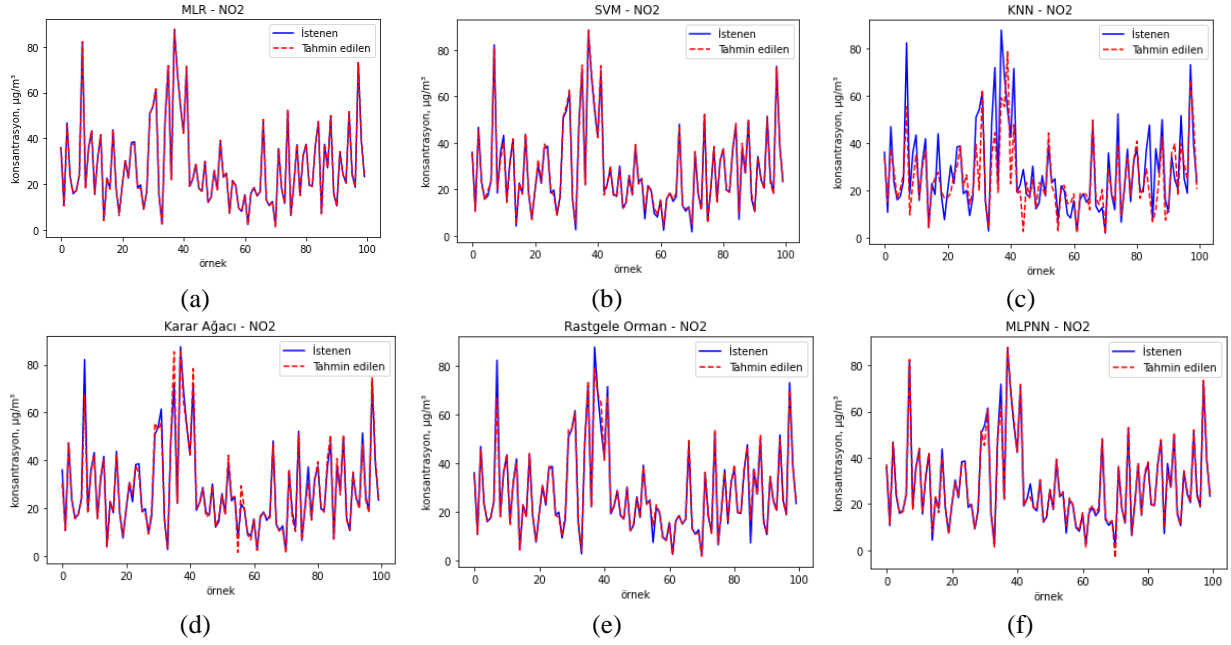
Şekil 3.  $PM_{10}$  kirleticisi tahmini için (a) MLR, (b) SVM, (c) KNN, (d) Karar ağacı, (e) Rastgele orman ve (f) MLPNN yöntemleri kullanılarak elde edilen grafikler.

$SO_2$  kirleticisine ilişkin tahmin edilen ve istenen veriler karşılaştırılmalı olarak Şekil 4' te verilmiştir. Rastgele Orman ve Karar Ağacı yöntemleri ile yapılan tahminlerin MLR, KNN ve SVM yöntemlerine kıyasla istenen değerlerle daha iyi örtüştüğü görülmektedir.



Şekil 4. (a) MLR, (b) SVM, (c) KNN, (d) Karar ağacı, (e) Rastgele orman ve (f) MLPNN yöntemleri ile  $SO_2$  kirleticisi tahmini için elde edilen grafikler.

Çeşitli makine öğrenme yöntemleri ile gerçekleştirilen  $NO_2$  tahminine ilişkin grafikler, Şekil 5' te istenen değerlerle birlikte sunulmuştur. Şekil 5 (a) ve (b)'den görüldüğü üzere, MLR ve SVM kullanılarak istenen değerlere oldukça yakın sonuçlar elde edilmiştir. KNN yöntemi diğer yöntemlere kıyasla daha düşük başarımla göstermiştir.



Şekil 5. NO<sub>2</sub> kirlenici tahmini için (a) MLR, (b) SVM, (c) KNN, (d) Karar ağacı, (e) Rastgele orman ve (f) MLPNN yöntemleri kullanılarak elde edilen grafikler.

Kastamonu için yapılan SO<sub>2</sub> hava kirlenici tahmin çalışmasında [5], YSA, Rastgele Orman, KNN, Lojistik Regresyon, Lineer Regresyon, Karar Ağacı ve Basit Bayes yöntemleri kullanılmış ve Karar Ağacı ve Rastgele Orman yöntemleri ile en yüksek performans ( $R^2 = 0.97$ ) ve Lineer Regresyon ile en düşük performans ( $R^2 = 0.30$ ) elde edilmiştir. Bu çalışmada SO<sub>2</sub> için, Rastgele Orman en yüksek performansı ( $R^2 = 0.96$ ) ve SVM en düşük performansı ( $R^2 = 0.76$ ) sunmuştur. [5] çalışmasına kıyasla çok daha fazla giriş parametresi kullanılmıştır. Çalışma [28]'de PM<sub>10</sub> kirlenicisine dayalı olarak hava kirliliği tahmini yapılmış, 4 ve 5 değişken için Regresyon ve YSA yöntemleri kullanılmıştır. Regresyon analizi ile elde edilen MSE değerleri 4 değişken için 297,784 ve 5 değişken için 384,584' tür. 4 ve 5 değişken için YSA kullanılarak sırasıyla 511,167 ve 480,603 MSE değerleri elde edilmiştir. Bu çalışmada ise PM<sub>10</sub> için daha yüksek bir öngörü sağlanmış, MLR yöntemi kullanıldığında elde edilen MSE = 259,639 ve MLPNN kullanıldığında ise MSE = 275,197 olarak elde edilmiştir.

Atina (Yunanistan) için yapılan hava kirliliği tahmin çalışmasında [29], NO<sub>2</sub>, NO, O<sub>3</sub>, CO ve SO<sub>2</sub> kirlenicilerine odaklanılmıştır. MLR ve ileri beslemeli YSA yöntemleri kullanılarak bu 5 atmosferik kirleniciye ilişkin konsantrasyon tahmini yapılmıştır. NO<sub>2</sub> ve O<sub>3</sub> kirlenicileri ele alındığında  $R^2$  değeri her iki yöntem için sırasıyla 0,69 ve 0,8 olarak hesaplanmıştır. CO kirlenicisine ait veriler için MLR yöntemi kullanıldığında elde edilen  $R^2$  değeri 0,73 ve ileri beslemeli YSA yöntemi kullanıldığında ise elde edilen  $R^2$  değeri 0,76 olmaktadır. Son olarak SO<sub>2</sub> kirlenicisi göz önüne alınarak yapılan tahminde, MLR yöntemi kullanılarak bulunan  $R^2$  0,31 ve ileri beslemeli YSA kullanılarak bulunan  $R^2$  0,29' dur. Bu çalışmada, [29] çalışması ile benzer şekilde MLR ve MLPNN yöntemleri de kullanılmıştır. NO<sub>2</sub>, O<sub>3</sub>, CO ve SO<sub>2</sub> kirlenicilerine ilişkin kirlenici konsantrasyonu tahmini sonrası elde edilen  $R^2$  değerleri sırasıyla Tablo 2' den de görüleceği üzere 0,999 (MLR) ve 0,98 (MLPNN); 0,61 (MLR ve MLPNN); 0,76 (MLR) ve 0,80 (MLPNN); 0,81 (MLR) ve 0,78 (MLPNN)'dir.

Bu çalışmada, tek bir hava kirlenicisi değil önemli hava kirlenicilerinden PM<sub>10</sub>, CO, SO<sub>2</sub>, NO<sub>2</sub> ve O<sub>3</sub> dikkate alınarak bu kirlenicilerin konsantrasyonlarına dayalı olarak etkili bir hava kirliliği tahmini sunulmuştur. Ayrıca birçok makine öğrenmesi yönteminin (MLR, SVM, KNN, Karar Ağaçları, Rastgele Orman ve MLPNN) kullanılması çalışmayı daha kapsamlı kılmıştır.

Literatürdeki benzer çalışmalardan da görüleceği üzere giriş parametreleri seçimi, kullanılan yöntemlerin performansı üzerinde etkilidir. Giriş ve çıkış parametrelerine ilişkin korelasyon tablosu dikkate alınarak sadece aralarında güçlü bir ilişki bulunan parametreler tahmin işleminde giriş olarak kullanılabilir. Bu durum, yöntemlerin performansını iyileştirerek yüksek öngörülü tahminler gerçekleştirilmesine yardımcı olabilir.



#### 4. SONUÇ

Günümüzde çeşitli nedenlerle şehirlerde artan nüfus yoğunluğu, beraberinde endüstriyel faaliyetler ve karayolu trafiğinde artış getirmiştir. Bu durum, şehirlerin hava kalitesinin her geçen gün bozulmasında önemli rol oynamaktadır. Bu etkilerin görüldüğü yerlerden biri, İstanbul ili Başakşehir ilçesidir. Çalışma kapsamında Başakşehir için hava kirliliği tahmini, MLR, SVM, KNN, Karar Ağaçları, Rastgele Orman ve MLPNN yöntemleri ile PM<sub>10</sub>, CO, SO<sub>2</sub>, NO<sub>2</sub> ve O<sub>3</sub> konsantrasyonlarına dayalı olarak tahmin edilmiştir. Kullanılan yöntemler arasında PM<sub>10</sub>, CO, SO<sub>2</sub> ve O<sub>3</sub> için Rastgele Orman ve NO<sub>2</sub> için MLR yöntemi, en az hata ile daha başarılı kirlenici konsantrasyonu tahmini gerçekleştirmiştir.

Hava kirliliğine etki eden kirlenicilerin yüksek başarımla tahmini, günlük ortalama kirlenici konsantrasyonlarının sağlık açısından limitleri aşması durumunda, yetkililerin önleyici adımlar atmasına imkan tanıyacaktır. Bu çalışma, gerek İstanbul' un diğer ilçeleri eklenerek tüm şehirdeki gerekse diğer büyük şehirlerdeki hava kirliliğini tahmin etmek ve analiz etmek amacıyla kapsamı genişletilip kullanılabilir. Ayrıca hava kirliliğinin ve dolayısıyla iklim değişikliğinin şehir sakinleri üzerindeki etkisini daha iyi anlamada ve sağlığa olumsuz etkileriyle mücadelede ilgili kurum ve kuruluşlara yardımcı olabilir. Çalışmada kullanılan hava kirlenici verileri, daha fazla çevresel veri (örneğin, meteoroloji ve trafik verileri) ile birleştirilerek makine öğrenimi gerçekleştirilebilir, böylece tahmin doğruluğu artırılabilir ve kirlilik seviyesinin gerçek zamanlı tahmini yapılabilir.

#### Teşekkür

Yazarlar, İstanbul Büyükşehir Belediyesi Çevre Koruma ve Kontrol Daire Başkanlığı Çevre Koruma Müdürlüğü Hava Kalitesi İzleme Merkezi'ne, bu araştırma çalışmasını gerçekleştirmemizi sağlamak için hava kalitesi verilerini kullanıma sundukları için teşekkür eder.

#### Yazar Katkıları

Yazarlar çalışmaya eşit oranlı katkı sunmuşlardır.

#### Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler

#### KAYNAKÇA

- [1] WHO.(2021,20 Aralık). Ambient air pollution [Çevrimiçi].Erişim:https://www.who.int/teams/envir onment-climate-change-and-health/air-quality-and-health/ambient-air-pollution.
- [2] Ö. Zeydan, "2019 yılında Türkiye'deki partikül madde (PM10) kirliliğinin değerlendirilmesi", Journal of the Institute of Science and Technology, vol. 11, no.1, pp. 106-118, 2021.
- [3] T. Sarver, A. Al-Qaraghuli, and L. L. Kazmerski, "A comprehensive review of the impact of dust on the use of solar energy: History, investigations, results, literature, and mitigation approaches", Renewable and Sustainable Energy Reviews, vol. 22, pp. 698-733, 2013.
- [4] D. Sanjeev, "Implementation of machine learning algorithms for analysis and prediction of air quality", International Journal of Engineering Research & Technology (IJERT), vol. 10, no. 3, pp. 533-538, 2021.
- [5] Y. Gültepe, "Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme", Avrupa Bilim ve Teknoloji Dergisi, vol. 16, pp. 8-15, 2019.
- [6] M. E. Ekinçi, "Destek Vektör Regresyon ile hava kirliliği tahmini", Yüksek lisans tezi, Endüstri Mühendisliği Bölümü, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye, 2017.
- [7] M. E. Irmak, and İ. B. Aydılek, "Hava kalite indeksinin tahmin başarısının artırılması için topluluk regresyon algoritmalarının kullanılması", Academic Platform Journal of Engineering and Science, vol. 7, no. 3, pp. 507-514, 2019.
- [8] E. Arnaudo, A. Farasin, and C. Rossi, "A Comparative analysis for air quality estimation from traffic and meteorological data", Applied Science, vol. 10, no. 13, pp. 4587(1-20), 2020.
- [9] A. Altunkaynak, E. E. Başakın, and E. Kartal, "Dalgacık K-en yakın komşuluk yöntemi ile hava kirliliği tahmini", Uludağ University Journal of The Faculty of Engineering, vol. 25, no. 3, pp. 1547-1556, 2020.
- [10] Q. Zhang, F. Fu, and R. Tian, "A deep learning and image-based model for air quality estimation", Science of The Total Environment, vol. 724, pp. 138178 (1-11), 2020.
- [11] S. Aydın, M. Taşyürek, and C. Öztürk, "Derin Öğrenme Yöntemi ile İç Anadolu Bölgesi ve Çevresi Hava Kirliliği Tahmini", Avrupa Bilim ve Teknoloji Dergisi, pp. 168-173, 2021.
- [12] M. Alghith, R. Alawaji, S. H. Saleh, and S. Alh, "Air pollution forecasting using deep learning", International Journal of Online & Biomedical Engineering, vol. 17, no. 14, pp. 50-64, 2021.

- [13] K. Kaya, "Veri madenciliği yöntemleri kullanarak hava kirliliği tahmini", Yüksek lisans tezi, Bilgisayar Mühendisliği Bölümü, İstanbul Teknik Üniversitesi, İstanbul, Türkiye, 2019.
- [14] M. Gayathri, R. Shankar, and S. Duraisamy, "Air pollution prediction using data mining technique", International Research Journal of Engineering and Technology (IRJET), vol. 7, no. 8, pp. 4292-4297, 2020.
- [15] Y. Dokuz, A. Bozdağ, and B Gökçek, "Hava kalitesi parametrelerinin tahmini ve mekansal dağılımı için makine öğrenmesi yöntemlerinin kullanılması", Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, vol. 9, no. 1, pp. 37-47, 2020.
- [16] M. Strak, G. Weinmayr, S. Rodopoulou, J. Chen, K. de Hoogh, Z. J. Andersen et al., "Long term exposure to low level air pollution and mortality in eight European cohorts within the ELAPSE project: pooled analysis", BMJ 2021, vol. 374, no. 1904, pp. 1-11, 2021.
- [17] WHO global air quality guidelines, "Particulate matter (PM<sub>2.5</sub> and PM<sub>10</sub>), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide", Geneva: World Health Organization, 2021, p. 17.
- [18] S. Cindoruk, "Havadaki NO ve NO<sub>2</sub> parametrelerinin Marmara Temiz Hava Merkezi ölçümleri kapsamında incelenmesi", Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, vol. 7, no. 2, pp. 600-611, 2018.
- [19] D. Grano, "Clean Air Act requirements: Effect on Emissions of NO, from stationary sources. In: Ozkan, U.S., Agarwal, SK. And Marcelin, G. (Eds.), Reduction of Nitrogen Oxide Emissions, ACS Symposium Series 587", American Chemical Society, Washington, DC, pp. 14-31, 1995.
- [20] Resmi Gazete (Sayı: 26898). (2021, 20 Aralık). Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği [Çevrimiçi]. Erişim: <https://www.resmigazete.gov.tr/eskiler/2008/06/20080606-6.htm>.
- [21] T. C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı. (2021, 29 Aralık). Hava kalitesi izleme sistemi [Çevrimiçi]. Erişim: <https://sim.csb.gov.tr/Home/HKI?baslik=HAVZA%20%C4%B0ZLEME%20S%C4%B0STEM%C4%B0>.
- [22] UK AIR Air Information Resource. (2021, 29 Dec). Effects of air pollution [Online]. Available: <https://uk-air.defra.gov.uk/air-pollution/effects>.
- [23] İstanbul Büyükşehir Belediyesi Çevre Koruma ve Kontrol Daire Başkanlığı Çevre Koruma Müdürlüğü Hava Kalitesi İzleme Merkezi. (2021, 31 Aralık). Başakşehir (Sanayi-Kentsel) [Çevrimiçi]. Erişim: <https://havakalitesi.ibb.istanbul/Pages/AirQualityDetails/6d169752-eabc-4f7e-87ea-6cf10b452486>.
- [24] T. Hastie, R. Tibshirani, J. H. Friedman, and J. H. Friedman, "The elements of statistical learning: data mining, inference, and prediction", Springer, vol. 2, pp. 1-758, 2009.
- [25] S. Tolun, "Destek vektör makineleri: Banka başarısızlığının tahmini üzerine bir uygulama", İktisadî Araştırmalar Vakfı, 2008.
- [26] J. Y. Hsia, and C. J. Lin, "Parameter Selection for Linear Support Vector Regression", IEEE Transactions on Neural Networks and Learning Systems, vol. 31, no. 12, pp. 5639-5644, 2020.
- [27] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation", PeerJ Computer Science, vol. 7, pp. 1-24, 2021.
- [28] İ. Akbulut, and B. Özcan, "Hava Kirliliği Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma", Kocaeli Üniversitesi Fen Bilimleri Dergisi vol. 3, no. 1, pp. 12-22, 2020.
- [29] A. Alimissis, K. Philippopoulos, C.G. Tzani, and D. Deligiorgi, "Spatial estimation of urban air pollution with the use of artificial neural network models", Atmospheric Environment, vol. 191, pp. 205-213, 2018.