

## PAPER DETAILS

TITLE: PM10 Parametresinin Makine Öğrenmesi Algoritmaları ile Mekânsal Analizi, Kayseri İli  
Örneği

AUTHORS: Begüm GÖKÇEK,Nuray SASA,Yesim DOKUZ,Aslı BOZDAG

PAGES: 65-80

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/1712337>



## **PM<sub>10</sub> Parametresinin Makine Öğrenmesi Algoritmaları ile Mekânsal Analizi, Kayseri İli Örneği**

### **Spatial Analysis of PM<sub>10</sub> Parameter by Machine Learning Algorithms, City of Kayseri**

**Öznur Begüm Gökçek <sup>1\*</sup>, Nuray Şaşa <sup>1</sup>, Yeşim Dokuz <sup>2</sup>, Aslı Bozdağ <sup>3</sup>**

<sup>1</sup> Niğde Ömer Halisdemir Üniversitesi Mühendislik Fakültesi Çevre Mühendisliği Bölümü, Niğde, TÜRKİYE

<sup>2</sup> Niğde Ömer Halisdemir Üniversitesi Mühendislik Fakültesi Bilgasayar Mühendisliği Bölümü, Niğde, TÜRKİYE

<sup>3</sup>Niğde Ömer Halisdemir Üniversitesi Mühendislik Fakültesi Harita Mühendisliği Bölümü, Niğde, TÜRKİYE

Sorumlu Yazar / Corresponding Author \*: begumgokcek@ohu.edu.tr

Geliş Tarihi / Received: 18.04.2021

Araştırma Makalesi/Research Article

Kabul Tarihi / Accepted: 30.08.2021

DOI:10.21205/deufmd.2022247008

Atıf Şekli/How to cite: GÖKÇEK, Ö.B., ŞAŞA, N., DOKUZ, Y., BOZDAĞ, A.(2022). PM<sub>10</sub> Parametresinin Makine Öğrenmesi Algoritmaları ile  
Mekânsal Analizi, Kayseri İli Örneği. DEUFMD, 24(70), 65-80.

#### **Öz**

Hava kirliliğinin son yıllarda artışı ile alınacak olan erken önlemler dâhilinde hava kirliliği tahmininin yapılması insan ve çevre sağlığına verilebilecek zararın en aza indirilmesinde önemlidir. Bu çalışmada günlük ortalama hava kirliliği miktarının, önemli bir hava kirletici olan PM<sub>10</sub> konsantrasyonu üzerinden tahminlenmesi ve hava kirliliğinin çevresel ve mekânsal modellenmesi amaçlanmıştır. Tahminleme modeli, Orta Anadolu Bölgesinde yer alan Kayseri ilinde bulunan 3 istasyondan alınan 2010-2018 yılları arasında ölçülen PM<sub>10</sub> konsantrasyonu verileri kullanılarak makine öğrenmesi algoritmaları (kNN DVR, RF, ANN, Lineer Regresyon) ile eğitilmiştir. Kayseri'deki 3 istasyonun 2010-2018 yılları arasındaki PM<sub>10</sub> konsantrasyon değerleri girdi olarak verilmiş ve 2019 yılına ait PM<sub>10</sub> konsantrasyon değerleri tahmin edilmiştir. En iyi sonuçlar 3 istasyon için de Destek Vektör Regresyonu algoritması ile elde edilmiş olup Trafik bölgesi için R<sup>2</sup>:0.85, RMSE:17.57, MAE:10.17; Hürriyet bölgesi için R<sup>2</sup>:0.73, RMSE:34.91, MAE:24.61 ve OSB bölgesi için R<sup>2</sup>:0.82, RMSE:41.71, MAE:21.62 olarak tespit edilmiştir. Ayrıca elde edilen tahmini konsantrasyon sonuçlarının mekânsal dağılımı (CBS) ve değişimi de analiz edilmiştir.

**Anahtar Kelimeler:** Makine öğrenmesi algoritmaları, PM<sub>10</sub>, destek vektör algoritması, CBS, mekânsal analiz

#### **Abstract**

With the increase of air pollution in recent years, it is important to make an estimation of air pollution within the scope of early measures to be taken in minimizing the damage to human and environmental health. In this study, it is aimed to estimate the daily average amount of air pollution

from the PM<sub>10</sub> concentration, which is an important air pollutant, and to model the environmental and spatial air pollution. The prediction model was trained with machine learning algorithms (kNN, DVR, RF, ANN, Linear Regression) using PM<sub>10</sub> (particulate matter) concentration data measured between 2010-2018 from 3 stations in Kayseri, Central Anatolia. PM<sub>10</sub> concentration values of 3 stations in Kayseri between 2010-2018 were given as input and PM<sub>10</sub> concentration values for 2019 were estimated. The best results were obtained with Support Vector Regression algorithm for all three stations. For the Traffic region, R<sup>2</sup>: 0.85, RMSE: 17.57, MAE: 10.17; For Hurriyet region, R<sup>2</sup>: 0.73, RMSE: 34.91, MAE: 24.61 and for OSB region R<sup>2</sup>: 0.82, RMSE: 41.71, MAE: 21.62. Also, the spatial distribution and variation of the estimated concentration results were analyzed by the Geographical Information System (GIS).

**Keywords:** Machine learning algorithms, PM<sub>10</sub>, Support vector algorithm, GIS, spatial analysis

## 1. Giriş

Son yıllarda gelişen sanayi, şehirleşme oranındaki artış ve ulaşımın gelişmesi ile artan hava kirliliği her geçen gün insan ve canlı yaşamını tehdit eder boyutu ulaşmaktadır.[1] Doğal olarak havada yer almayan kirleticilerin ortaya çıkması ya da zararlı boyutlarda olmayan kirletici partiküllerin (sağlığa konu olan partiküller, aerodinamik çapı 10 µm. nin altındaki partiküller) havadaki miktarındaki artışı hava kirliliğini oluşturmaktadır. En önemli hava kirletici parametreleri, Partikül Madde (PM), Kükürt dioksit (SO<sub>2</sub>), Karbon monoksit (CO), Ozon (O<sub>3</sub>), Azotoksitler (NO<sub>x</sub>) ve Hidrokarbonlar (HC)'dır. Kirleticilerin kaynağı yangın, toz taşınımı gibi doğal kaynaklar olacağı gibi antropojenik faaliyetlerden olan fabrika, enerji tesisi, yakma tesisi ve inşaat kaynaklı da olabilmektedir [2].

Hava kirliliğinin özellikle insan sağlığı üzerindeki etkisinden dolayı kirliliğin belirlenmesi, kirletici düzeylerinin kontrol altında tutulması ve önlenmesi adına pek çok çalışma yapılmaktadır [3]. Hava kalitesi izleme çalışması bunlardan biridir. Bu izlemenin devamlı gerçekleşmesi için belirli noktalarda izleme istasyonları kurulmuştur. Ancak bu istasyonların kurulum ve işletme maliyetleri yüksek olduğundan sınırlı sayıda bulunmaktadır. Bu durumda kişilerin hava kirliliğine gerçek maruz kalım düzeyleri saptanamamaktadır. Hava kalitesini tahmin etmek amaçlı günümüzde analitik yöntemlerin dışında yapay zekâ teknolojilerinden olan makine öğrenmesi algoritmalarına yönelik tahminleme sistemleri

giderek artmaktadır [4-6]. Bu sistem geliştirilen bilgisayar programları ile hava kirliliğinin matematiksel olarak tahmininin yapılması işlemeye dayanmaktadır. Bu sistemler ile hava kirliliğine yönelik objektif ve daha hassas sonuçlar elde edilen çalışmalar yapılmaktadır. Bu matematiksel modelden istenen sonuçların yeni teknolojilerle belirli bir düzeyin altında tutulması ve geleceğe yönelik sağlıklı tahminlerde bulunulması gerekmektedir. Literatürde hava kalitesi parametrelerinin tahmini için çeşitli makine öğrenmesi algoritmaları kullanılarak çalışmalar yapılmıştır. Bu algoritmalar örnek olarak LASSO Regresyon [7-9], Destek Vektör Makinesi (DVM) [10-12], Rastgele Orman (RF) [13-17] ve k En Yakın Komşu algoritmaları (kNN) [18-20] sayılabilir. Hava kalitesi konsantrasyon tahmininde kullanılan yöntem ve algoritmaların başarısını etkileyen bazı etmenler bulunmaktadır. Bunlar; kullanılan verinin miktarı ve elde edildiği süre, incelenen bölgenin arazi kullanımı ve etki eden meteorolojik değişkenler olarak sıralanabilir. Literatürde farklı etmenler kullanılarak PM<sub>10</sub> konsantrasyon değişimini, yüksek doğrulukla tahmin etmeye yönelik algoritmalar kullanan çalışmalar bulunmaktadır [21-24]. Çalışmalarda tahmin değerlerinin daha iyi yorumlanabilmesi için bölgesel analizler yapılması ve mekânsal dağılımının incelenmesi önem taşımaktadır. Elde edilen verilerin haritalandırılarak görselleştirilmesi ve bunun üzerinden analizler sağlanabilmesi bir sistemi gerektirmektedir. Coğrafi Bilgi Sistemleri modelleme çalışmaları için veri sağlamada veya modelleme çalışmalarından elde edilen sonuçların

görselleştirilmesinde yaygın olarak kullanılmaktadır [25,26]. CBS, mekânsal verinin toplanması, saklanması, saklanan verilerin kullanılarak yeni verilerin elde edilmesi, sorgulanması, düzenlenmesi, analiz edilmesi ve sonuçların grafik, harita veya 3 boyutlu görüntü şeklinde görsel hâle getirilmesine dayanan bir bilgi sistemidir [27-29]. CBS ortamında sıkılıkla toplanan ve depolanan mekânsal özelliği bulunan veriler (iklim değişikliği, arazi kullanım, bitki örtüsü, yer şekilleri, nüfus, yerleşme vs.) ve bu verilere ilişkin analizler makine öğrenmesi algoritmalarında kullanılmaya uygun niteliktir [30]. CBS bu kapsamda makine öğrenimi algoritmaları için veri kaynağı sağlarken aynı zamanda sınıflandırma, kümeleme, tahminleme gibi makine öğrenme algoritmalarına yönelik sonuçlarının görselleştirilmesinde etkin olarak kullanılmaktadır. Literatürde, hava kalitesine yönelik tahmin ve modelleme çalışmalarında CBS ile oluşturulan haritalardan yararlanılarak mekânsal ve zamansal değişimin ortaya konulduğu görülmektedir [31,32].

Bu çalışmada Kayseri'deki günlük ortalama hava kirliliğinin  $PM_{10}$  konsantrasyonu üzerinden tahminlenmesi ve hava kirliliğinin çevresel ve mekânsal modellenmesi amaçlanmıştır.  $PM_{10}$  verisi zamansal olarak düzenli olması ile erişilebilirliği açısından bu parametrenin seçilmesinde etkilidir. Tahminleme modeli ile istasyonlar arasında birbirlerine bağımlılıklarına bakarak gelecek tahmini yapmıştır. Bu amaçla 3 istasyondan 2010-2018 yılları arasında  $PM_{10}$  konsantrasyonu verileri kullanılarak makine öğrenmesi algoritmaları (kNN, DVR, RF, ANN, Lineer Regresyon) ile veriler eğitilmiş her bölgenin 2019 yılına ait tahmini, gerçek verileri verilmeden diğer bölgelerin 2019 verileri kullanılarak elde edilmiştir. Bu şekilde bölgesel bağımlılık elde edilerek geleceğe yönelik tahmin yapılmıştır. Elde edilen tahmin değerlerine göre mekânsal dağılımın ve değişimin CBS yardımıyla analizi de yapılmıştır.

## 2. Materyal ve Yöntem

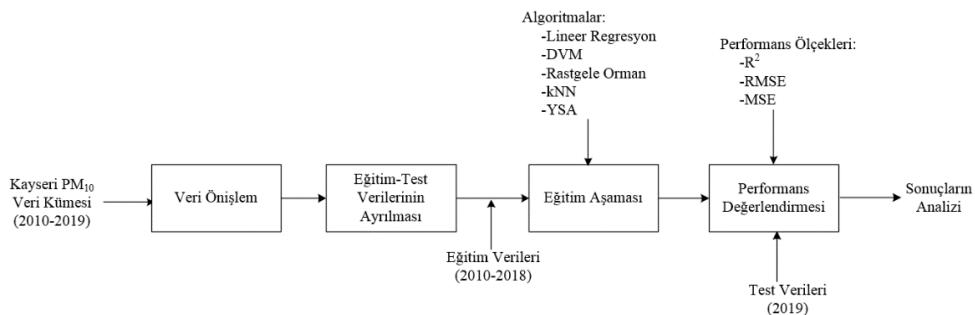
### 2.1. Örnekleme noktaları ve örnekleme analizleri

Türkiye'de birçok ilde olduğu gibi Kayseri il genelinde zaman zaman hava kirliliği problem oluşturmaktadır [1]. Hava kirliliğinin araştırmasının yanında kirliliğin giderilmesi adına çözüm ortaya konulması önem arz etmektedir. Kayseri ilinde Ulusal Hava Kalitesi İzleme Ağı bünyesinde 2007 yılından itibaren anlık ve sürekli izleme ağına geçilmiştir [33]. Hava kalitesi düzeyini ölçmek amacıyla hava kalitesi Gözlem İstasyonları kurularak saatlik ortalama  $SO_2$ ,  $PM_{10}$ , hava sıcaklığı, hava basıncı, nem, rüzgâr yönü ve rüzgâr hızı ölçülmektedir. Bu çalışma için  $PM_{10}$  konsantrasyon verileri Kayseri İl hava kalitesi ölçüm istasyonları olan Trafik, Hürriyet ve OSB istasyonlarından günlük ortalama veriler olarak temin edilmiştir.

Makine öğrenmesi tekniklerinin başarılı sonuçlar verebilmesi için eksik verilerin bir önişlem aşaması olarak tamamlanması gerekmektedir. Seçilmiş olan zaman aralığında çeşitli sebeplerden dolayı istasyonlarda ölçümlerde eksiklik veya kayıp değerler bulunmaktadır. Bu eksik ve kayıp değerlerin, o niteliğe ait ortalama değerlerle doldurulması sağlanmıştır.

### 2.2. Makine öğrenmesi algoritmaları

Bu çalışmada makine öğrenmesi algoritmalarından Lineer Regresyon, Destek Vektör Regresyon, Rastgele Orman, k En Yakın Komşu ve Yapay Sinir Ağları algoritmaları kullanılmıştır. Kullanılan algoritmalar, Weka makine öğrenmesi yazılımı [34] kullanılarak mevcut veri üzerinde uygulanmış ve sonuçlar elde edilmiştir. Önerilen yönteme ait blok diyagram Şekil 1'de sunulmuştur. Şekil 1'de gösterildiği üzere, ilk olarak Kayseri  $PM_{10}$  konsantrasyon verileri toplamış ve önişlemden geçirilmiştir. Daha sonra, 2010-2018 yılları arasındaki veriler eğitim, 2019 yılındaki veriler test için ayrılmıştır. Eğitim verileri kullanılarak makine öğrenmesi algoritmaları çalıştırılmıştır. Daha sonra test verileri ve performans ölçekleri kullanılarak algoritmaların performansları değerlendirilmiştir. Son olarak algoritmaların bulmuş olduğu tahmin sonuçlarının analizi yapılmıştır.

**Şekil 1.** Önerilen yönteme ait blok diyagram

Çalışmada kullanılan algoritmalar farklı parametrelerle test edilmiş ve en iyi performansı gösteren parametreler kullanılmıştır.

### 2.2.1. Lineer Regresyon Algoritması

Lineer regresyon iki ya da daha fazla değişken arasındaki ilişkiyi ölçmek için kullanılan metottür. En basit makine öğrenme modelidir. Bu algoritma neden ve sonuç arasında lineer ilişki olup olmadığını belirler. Eğitim kümesi kurularak hipotezdeki uygun parametre seçilir ve gelecekteki farklı veri girdilerine karşılık tahmin yapılır[35]

### 2.2.2. Destek Vektör Makinesi Algoritması

DVM algoritması iki veya daha fazla boyuttaki noktaları birbirlerinden ayıran bir çizgi, düzlemler veya hiperdüzlemler üreterek sınıflandırma yapmaya çalışan ayrımcı bir sınıflandırma algoritmasıdır [36]. DVM algoritması, farklı sınıflara ait noktalar arasındaki uzaklığı maksimize edecek en uygun doğruya bulmaya çalışarak sınıflar arasındaki ayrimı mümkün olduğu kadar iyi belirlemeye çalışmaktadır. Destek Vektör Regresyon (DVR) algoritması ise DVM algoritmasının regresyon amacıyla özelleştirilmiş türüdür.

Bu çalışmada DVR algoritması için radyal tabanlı fonksiyon kullanılmış, C ve gamma parametreleri sırasıyla 100 ve 0.01 olarak seçilmiştir.

### 2.2.3 Rastgele Orman Algoritması

Rastgele orman algoritmasında birden fazla karar ağacı oluşturularak bir orman meydana getirilir [37]. Rastgele orman algoritması girdi parametreler seti içerisinde rastgele parametreler seçerek bu parametreler ile çok sayıda karar ağacı oluşturmaktadır. Oluşturulan bu karar ağacılarının sonuçları kullanılarak algoritmanın sınıflandırma çıktıları hesaplanmaktadır. Bu sayede, birbirinden bağımsız veya ilgisiz parametreler farklı karar ağacılarıyla değerlendirildiği için rastgele orman algoritması başarılı sonuçlar üretmektedir.

Bu çalışmada rastgele orman algoritması için 200 ağaç kullanılmıştır.

### 2.2.4 k En Yakın Komşu Algoritması

k-En Yakın Komşu (kNN) algoritması etiketleme bilgisi bulunmayan gözlemlerinin birbirlerine yakınlık derecesi göz önünde bulundurularak yapılan sınıflandırma işlemidir. Bu algoritmanın uygulama aşamasında öncelikle eğitim verisi kullanılarak sistem eğitilir. Eğitim setinde sınıflandırma bilgisi bulunan veriler mevcuttur. Eğitim seti verildikten sonra kullanıcı tarafından bir k değeri tespit edilir. Sistem öğrendiği eğitim setindeki sınıfları göz önünde bulundurarak yeni verilen gözlem verilerinden birbirine en yakın bulunan k tane komşu veriyi sınıflandırır. Verilerin birbirine olan yakınlığını ölçmek için Öklid uzaklığı, Jaccard uzaklığı, Manhattan uzaklığı gibi yöntemler kullanılır [38].

Bu çalışmada kNN algoritması için komşu sayısı olarak 20 kullanılmıştır.

### 2.2.5 Yapay Sinir Ağları

Yapay sinir ağları (Artificial Neural Networks – ANN), insanların beynindeki nöronlar ve bu nöronların kurdugu bağlantılarından ilham alınarak geliştirilmiş hesaplama sistemleridir [39]. Yapay sinir ağları kendilerine gösterilen örneklerden öğrenmekte ve yeni gelen örnekleri de öğrenme sistemine dahil etmektedir.

Bu çalışmada yapay sinir ağ modeli olarak her birinde 3 nöron bulunan 3 gizli katman kullanılmış, iterasyon sayısı 500 ve ağırlık optimizasyonu için Kısıtlı Hafıza Broyden-Fletcher-Goldfarb-Shanno (Limited Memory Broyden-Fletcher-Goldfarb-Shanno - LBFGS) algoritması seçilmiştir.

### 2.3. Performans metrikleri

Makine öğrenmesi algoritmalarının performanslarının belirlenebilmesi için çeşitli metrikler kullanılmıştır. Bu metrikler arasında en yaygın kullanılanları  $R^2$ , RMSE ve MAE'dir.  $R^2$  gerçek test değerleri ile algoritmaların çıkardığı sonuçların birbirine ne kadar uyumlu olduğunu gösteren bir metiktir. RMSE ve MAE metrikleri ise gerçek test değerleri ile algoritmaların çıktıları arasındaki hatayı ifade etmektedir. Kullanılan metriklere ait formüller sırasıyla Eşitlik 1-3'te verilmiştir.

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

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

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

### 2.4. Mekansal analiz

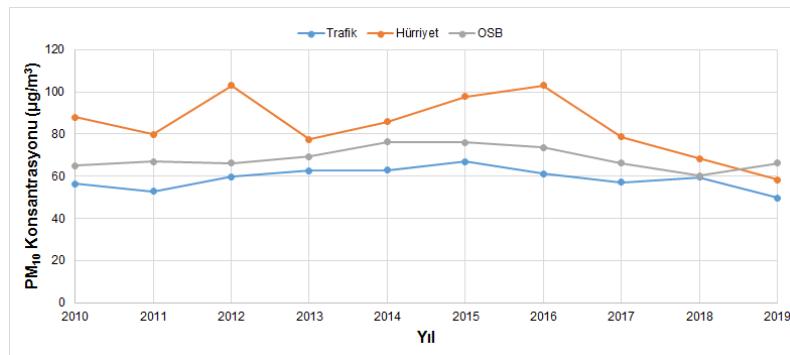
2010-2019 yılları arasında istasyon verilerinin yıllık ortalamaları ve mevcut analizlere göre yapılan tahminleri incelemek amacıyla Coğrafi Bilgi Sistemlerinden (CBS) yararlanılmıştır. CBS uygulamalar için veri toplama, saklama, sorgulama, ilişkilendirme ve modelleme çalışmalarından elde edilen sonuçların görselleştirilmesinde yaygın olarak kullanılmaktadır [25,26]. Hava kirliliği değişiminin ortaya konulmasında CBS uygulamalarından mekânsal dağılımin analiz yöntemleri (Kriging ve IDW yöntemleri) sıkılıkla kullanılmaktadır [40-44].

Bu çalışmada CBS yazılımlarından biri olan ArcGIS 10.6.1 yazılımı yardımıyla istasyonların yıllara göre değişen verilerinin kent üzerindeki mekânsal dağılımları IDW yöntemiyle analiz edilmiştir. IDW, birbirine yakın olan şeýlerin birbirine uzak olandan daha benzer olduğunu varsayıarak ölçülmemiş herhangi bir konum için tahmin konumunu çevreleyen ölçülmüş değerleri kullanarak bir değer tahmin etmektedir. IDW enterpolasyon yöntemiyle 2010, 2015 ve 2019 yıllarına ilişkin değişen veriler ortak lejand üzerinde görselleştirilerek yıllar arasındaki fark ortaya konulmuştur.

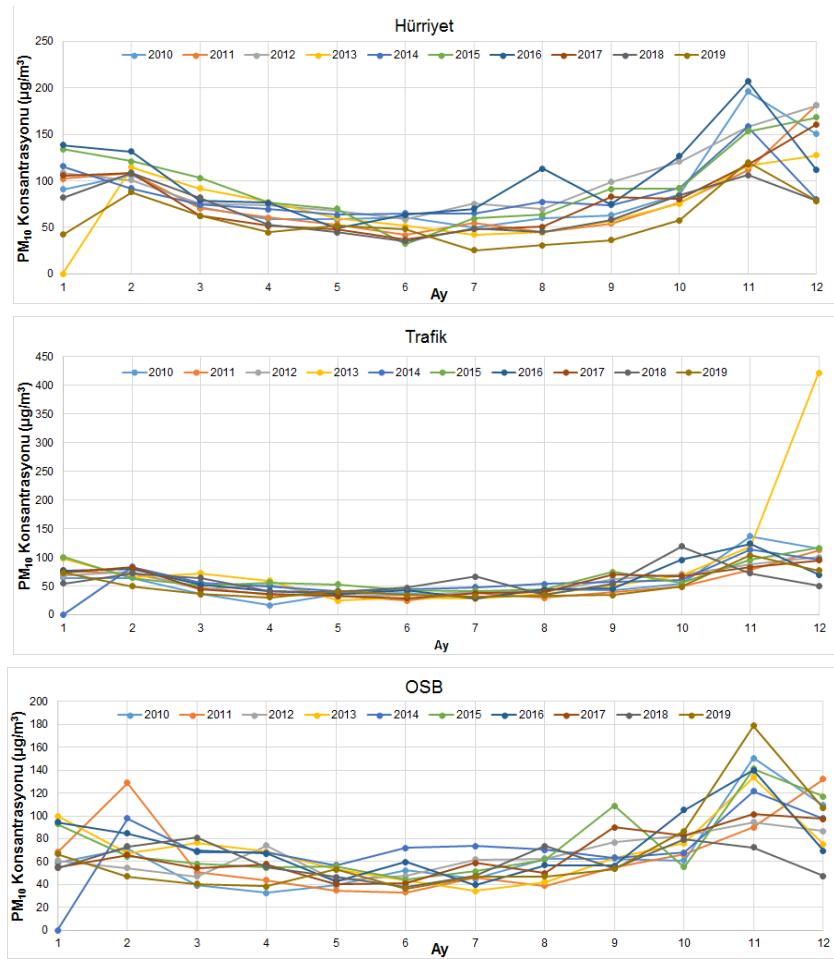
### 3.Bulgular ve Tartışma

#### 3.1. Çalışma bölgesi ve hava kirliliği verileri

Ulusal Hava Kalitesi İzleme Ağı tarafından elde edilen veriler ışığında Şekil 2'de seçilmiş olan üç bölge için (OSB, Trafik, Hurriyet) 2010-2019 yılları arası yıllık bazda  $PM_{10}$  konsantrasyonu değişimi, Şekil 3'te ise 2010-2019 yılları arasında üç bölge için  $PM_{10}$  konsantrasyonunun aylık değişimi verilmiştir.



**Şekil 2.** Hürriyet-Trafik ve OSB istasyonlarına ait 2010-2019 yılları arası PM<sub>10</sub> konsantrasyonu değişimi



**Şekil 3.** Hürriyet-Trafik ve OSB istasyonlarına ait 2010-2019 yılları arası PM<sub>10</sub> konsantrasyonu aylık değişimi

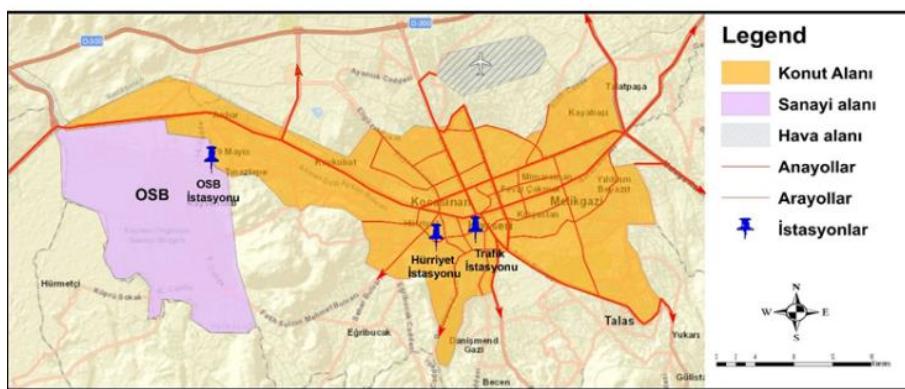
Çalışma kapsamında değerlendirilen istasyonların Şekil 2'de verilen yıllık ortalama  $PM_{10}$  ölçüm sonuçları incelendiğinde "Hava Kalitesi Değerlendirme ve Yönetimi Yönetmeliği"nde  $PM_{10}$  için belirtilen yıllık sınır değer olan  $40 \mu\text{g}/\text{m}^3$ 'ü tüm istasyonlarda aştiği görülmektedir. Çalışmada değerlendirilen 3 istasyonun Şekil 3'te verilen 2019 yılına ait aylık değerlendirme yapıldığından; her 3 istasyon içinde özellikle kış ayları olan Kasım, Aralık, Ocak ve Şubat aylarında  $PM_{10}$  değerlerinin ulusal sınır değer olan  $60 \mu\text{g}/\text{m}^3$ 'ü aşmıştır.

### 3.1.1 Coğrafi konumu

Kayseri, İç Anadolu Bölgesinin güneyinde Orta Kızılırmak bölümünde yer almaktadır.  $37^{\circ}45'$  ile  $38^{\circ}18'$  kuzey enlemleri ve  $34^{\circ}56'$  ile  $36^{\circ}58'$  doğu boyamları arasında yer almaktadır (Şekil 4).

16.917 km<sup>2</sup>lik yüzölçümüne sahip Kayseri ilinin denizden yüksekliği 1054 m'dir [45].

Kent, eski kent merkezi etrafında örümcek ağı morfolojisine uygun nitelikte yayılmıştır (Şekil 4). OSB bölgesi gelişikçe kent bu bölgeye doğru lineer bir yayılma göstermektedir. Kentin hava kalitesi düzeyinde yoğun konsantrasyon miktarlarının gözlediği kent merkezi ve OSB civarında üç istasyon (OSB, Trafik ve Hürriyet İstasyonu) yer almaktadır. Bu istasyonlardan Hürriyet İstasyonu konut sahası olarak kentin yoğun yerleşim alanlarının bulunduğu bölgede yer almaktadır. Trafik istasyonu ise eski kent merkezinin ve geleneksel ticaret merkezinin odağında ve günlük ihtiyaçlarına yönelik yaşıyanların ve turistlerin uğrak noktası olduğu trafığın en yoğun yaşandığı bölgede yer almaktadır.



**Şekil 4.** Kayseri kenti genel görünümü

### 3.2. Makine öğrenmesi algoritmaları

Makine öğrenmesi algoritmaları kullanılarak  $PM_{10}$  konsantrasyonu tahmini metoduna ait sonuçlar Tablo 1'de verilmiştir. Tabloda, her bölgeye ait sonuçlar için diğer bölgelerdeki  $PM_{10}$  konsantrasyon değerleri kullanılarak tahmin modelleri kurulmuş ve 2019 yılı  $PM_{10}$  konsantrasyonu ile ilgili bölgedeki tahminine ait sonuçlar gösterilmiştir. Bu şekilde bir şehirdeki farklı bölgeler arasında mekânsal bağ kurularak istenen bir bölgedeki değerin tahmini yapılmaktadır. Uygulanan algoritmalar ile veri setinde büyük veri ile çok sayıda özellik bulunuyorsa ve bunları yorumlayacak denklem ya da fonksiyon yok ise anlam çıkarmak veya çeşitli sebeplerden dolayı istasyonlarda ölçümlerin eksik olması, kayıp değerlerin olması durumunda veri setindeki kayıp değerler için o

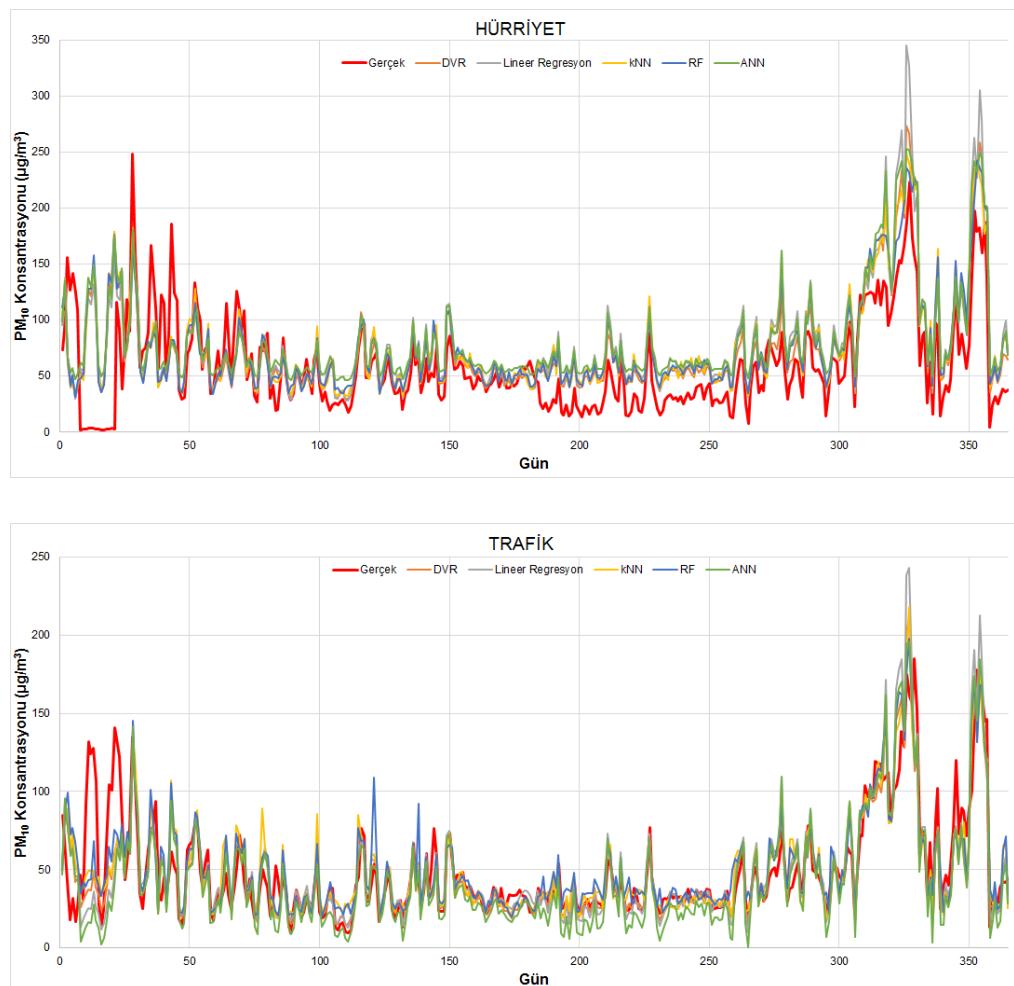
niteliğe ait ortalama değerlerle doldurulması sağlanmaktadır. Bunun için çözülmesi gereken problemi çözerken doğru veri ile algoritmayı beslemek çok önemlidir.

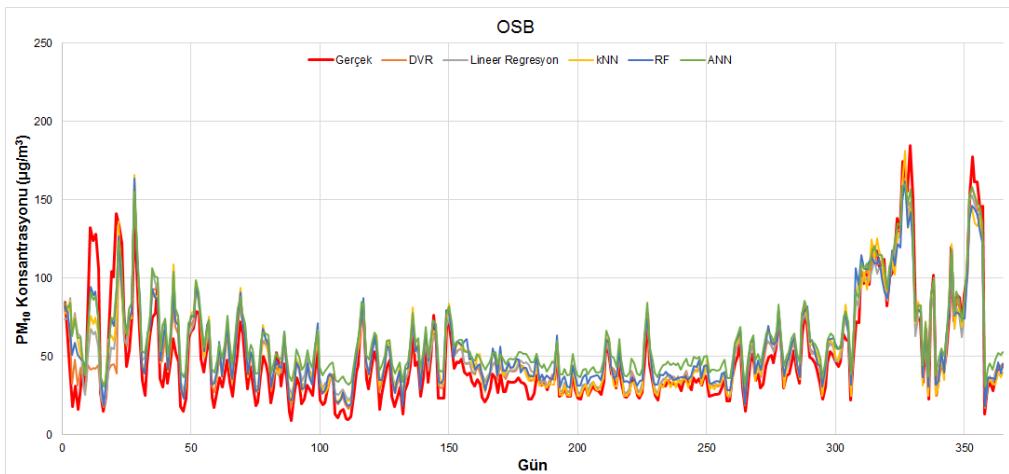
Sonuçlar incelendiğinde Trafik, Hürriyet ve OSB bölgelerindeki istasyonlarda en iyi sonucun DVR algoritması tarafından üretildiği görülmektedir. En iyi sonuçlar Trafik bölgesi için DVR algoritması ile  $R^2=0,85$ , RMSE=17,57, MAE=10,17; Hürriyet bölgesi için DVR algoritması ile  $R^2=0,73$ , RMSE=34,91,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

**Tablo 1.** Makine öğrenmesi algoritmalarıyla  $PM_{10}$  konsantrasyon tahmini deney sonuçları

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

Üç bölge için  $PM_{10}$  konsantrasyonlarının 2019 yılı için çalıştırılan algoritmalar tarafından yapılan tahminlerin gerçek  $PM_{10}$  değerleriyle karşılaştırımalı olarak incelenmesi için algoritmalar tarafından tahmin edilen  $PM_{10}$  konsantrasyon değerleri ile gerçek değerlerin 2019 yılı için gün bazında karşılaştırması Şekil 5'te sunulmuştur.





**Şekil 5.** Algoritmalar sonucu ile gerçek değerlerin yıllık olarak karşılaştırılması

Her üç bölge için sonuçlar incelendiği zaman, algoritmaların genel olarak doğru değerler ürettiğinden görümektedir. Lineer Regresyon, RF ve ANN algoritmalarının gerçek sonuçlara göre yüksek ve düşük değerler ürettiğine benzer olarak gerçek değerler en uygun sonuçların DVR algoritması tarafından üretildiği görülmektedir. OSB bölgesi için yılın ilk aylar için algoritmaların tahminlerinin genel olarak düşük kaldığı ve ilerleyen aylarda sonuçların gerçek değerlere yaklaşığı gözlemlenmektedir. Algoritmaların hepsinin birbirine benzer sonuçlar ürettiği görülmektedir. Hürriyet bölgesi için genel olarak algoritmaların ya düşük veya da yüksek sonuçlar ürettiği görülmektedir. Bu algoritmalar içerisindeen en iyi sonucun DVR algoritması tarafından elde edilebildiği de görülmektedir. DVR algoritması çok çeşitli verilerde daha verimli çalışmaktadır ve daha iyi sonuç vermektedir [10-12]. En kötü sonucun da kNN algoritması tarafından elde edildiği görülmektedir. Bunun sebebi olarak, kNN algoritmasının eğitim ve test verileri arasındaki farklılıklarla daha duyarlı olduğu ve bu nedenle elde ettiği sonuçların daha kötü olduğu söylenebilir

Literatüre bakıldığından son yıllarda hava kirliliği üzerine çeşitli makine öğrenmesi algoritmaları kullanılarak farklı çalışmalar yapılmıştır. Fakat yapılan çalışmaların çoğunda daha az veri

użyulanlarak çalışmalar yapılmış ayrıca bögesel bir tahminden ziyade gelecek tahmini yapılmıştır. Yapılan bu çalışmaya benzer algoritmalar ve hava kirletici parametreler kullanılarak yapılan çalışmalarдан biri olan Ashayeri vd., PM<sub>2.5</sub> konsantrasyonunu tahmin etmek için Chicago'daki farklı kentsel mahallelerdeki hava kalitesi verilerini kullanarak en etkili algoritmayı bulmak için dokuz farklı makine öğrenmesi algoritmasını test etmişlerdir. Sonuç olarak, yapılan bu çalışmaya benzer şekilde DVR algoritmasının test edilen en iyi algoritma olduğu sonucuna varılmışlardır. DVR algoritması model performansını yıl boyunca %18,4 ve aylık veri kümeleri için %98,7'ye kadar arttığı belirtilmiştir [46]. Bu çalışmada tahmin edilen hava kalitesi parametresi ile aynı parametrenin kullanıldığı Choubin vd., tarafından yapılan çalışmada Barselona Eyaletindeki 75 istasyondaki yıllık PM<sub>10</sub> için tehlikeli alanları tahmin etmek adına RF, Torbalı Sınıflandırma ve Regresyon Ağaçları (Torbali CART) ve Karışım Ayırım Analizi (MDA) gibi makine öğrenmesi algoritmaları kullanılmışlardır. Sonuçlarda üç makine öğrenmesi modelinin de mükemmel sonuç (doğruluk: >%87 ve hassasiyet: >%86) verdiği belirtilmiştir. Torbalı CART ve RF modellerinin aynı ve MDA modeline göre daha yüksek performansa sahip olduğu belirtilmiştir [22]. Yapılan başka bir çalışmada, Avusturya

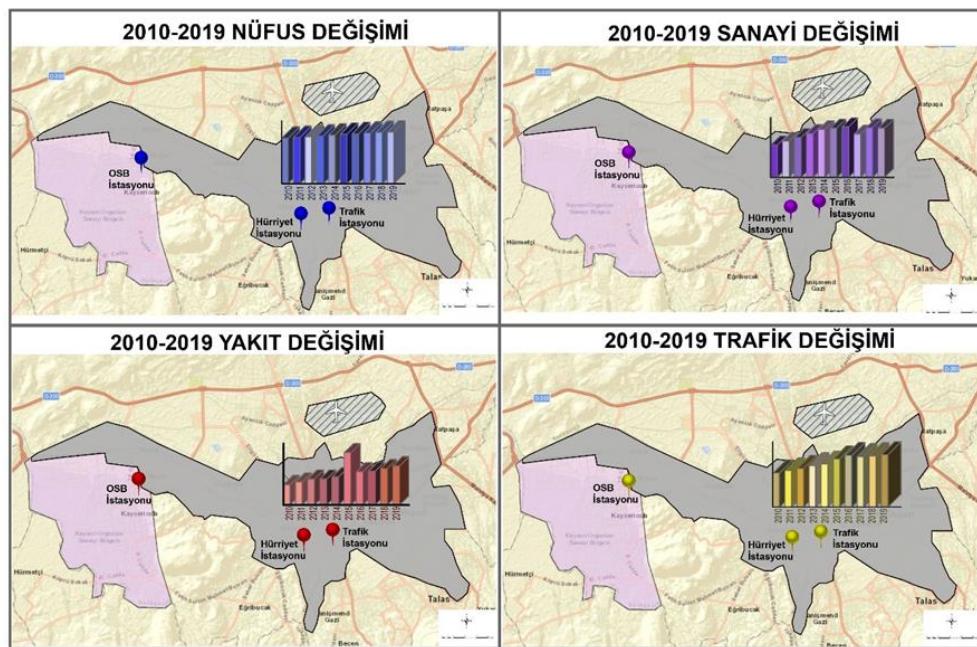
Graz'daki COVID-19 kısıtlaması sırasında hava kalitesi iyileştirmelerini analiz etmek için bir makine öğrenmesi modeli geliştirilmiştir. Graz'daki beş ölçüm istasyonundan NO<sub>2</sub>, PM<sub>10</sub> ve O<sub>3</sub> konsantrasyonları seçilmiş ve Rastgele Orman (RF) modeli için hedef değişken olarak kullanılmıştır. Makine öğrenmesi modellerinin konsantrasyonları tahmin etmede yüksek performans gösterdiği sonucuna varılmıştır. Kentin kısıtlama dönemlerinde ortalama konsantrasyon düşüşleri NO<sub>2</sub> ve PM<sub>10</sub> için sırasıyla %36,9-41,6 ve %6,6-14,2 olduğu ayrıca O<sub>3</sub> için %11,6-33,8'lük bir artış olduğu tahmini yapılmıştır [47]. PM<sub>10</sub> parametresi üzerine Avustralya'nın Moranbah maden kasabasındaki yapılan başka bir çalışmada, 2011 yılından beri PM<sub>10</sub> hava kalitesinin standartların üzerinde seyretmesinden dolayı ölçülen PM<sub>10</sub> konsantrasyonlarını modellemek ve meteorolojik olarak normalleştirmek için makine öğrenmesi algoritmalarından Gradyan Artırılmış Regresyon ve Rastgele Orman modelleri kullanılmıştır. Sonuçta en iyi performansı Rastgele Orman algoritmasının sağladığı belirtilmiştir [16]. Masood ve Ahmed (2020) yılında Delhi'de yaptıkları çalışmada bu çalışmada da kullanılan algoritmaların DVR ve YSA algoritmalarını kullanarak günlük PM<sub>2,5</sub> konsantrasyonlarını tahmin etmişlerdir. Sonuç olarak YSA'nın (eğitim ve test için korelasyon değeri sırasıyla 0,856 ve 0,730) PM<sub>2,5</sub> tahmini için DVR'den daha iyi tahmin doğruluğu gösterdiği belirtilmiştir [48].

Çevre ve Şehircilik Bakanlığı'nın 81 ildeki hava kalitesi izleme istasyonlarından aldığı verilerle oranını tespit ettiği havadaki partikül maddeler (PM<sub>10</sub>) "akciğerlere ulaşarak iltihaplanmaya ya da insanları çok olumsuz etkileyecək kalp ve

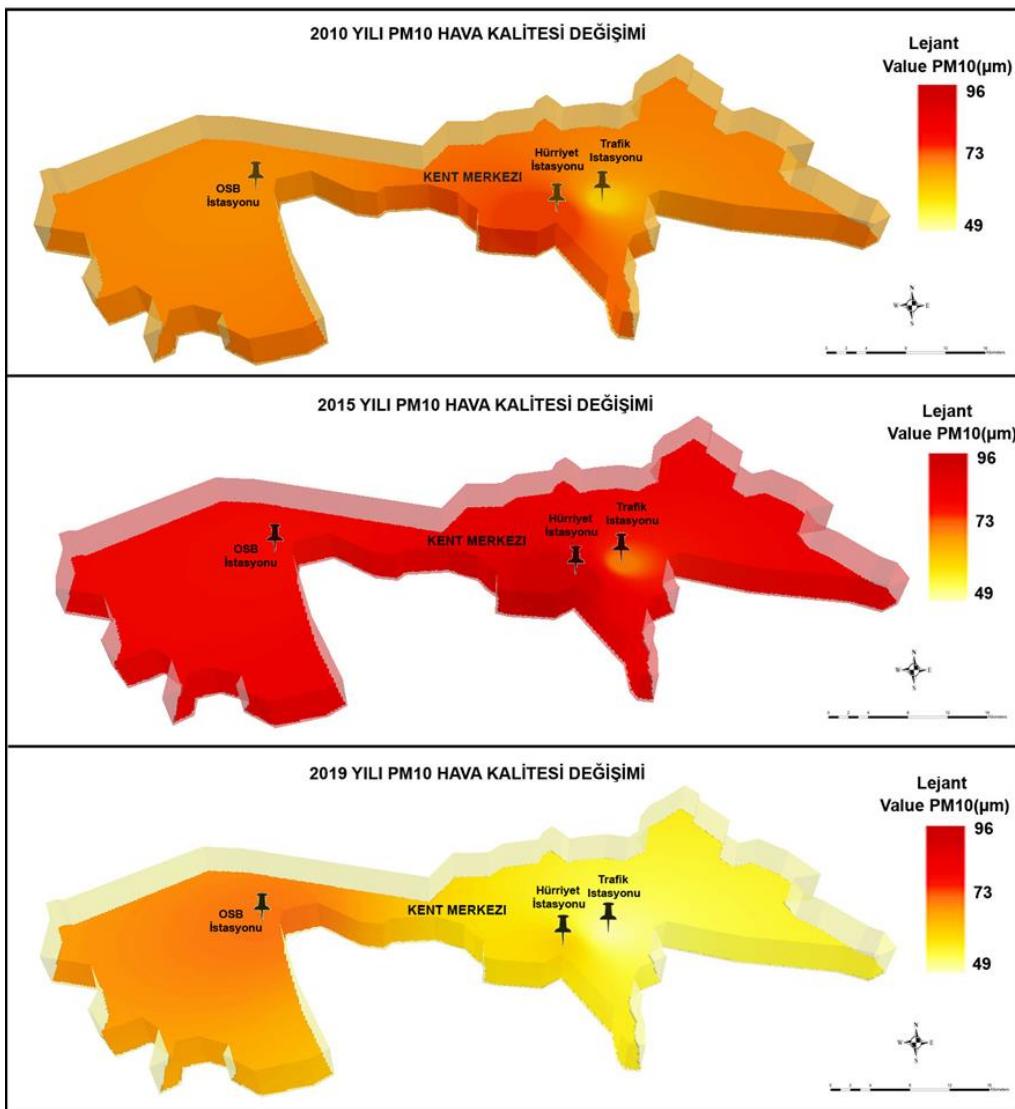
akciğer hastalıklarına neden" olabilmektedir. Dolayısıyla bu partiküllerin havadaki oranı, kirliliğinin en önemli göstergelerinden biri olarak kabul edilmektedir. Ancak Türkiye'nin mevcut yönetmelik ve uygulamalarda hava kalitesi ölçümünde sağlıklı seviye olarak kabul ettiği değerler(SO<sub>2</sub>:250 µg/m<sup>3</sup>, PM<sub>10</sub>:100 µg/m<sup>3</sup>, Avrupa Birliği (AB) için (SO<sub>2</sub>:125 µg/m<sup>3</sup>, PM<sub>10</sub>:50 µg/m<sup>3</sup>) ve DSÖ'nün kabul ettiği sınır değerlerden (SO<sub>2</sub>: 500 µg/m<sup>3</sup>, PM<sub>10</sub>: 50 µg/m<sup>3</sup>) çok daha yüksek olduğu belirtilmektedir [49].

### 3.3. Mekansal Analiz Sonuçları

Çalışmada PM<sub>10</sub> değerine etkileyen unsurlar grafik ve haritalar ile analiz edilmiştir (Şekil 6). Bu analizler 2010-2019 yılı kent merkezinin nüfus yoğunluğu, sanayi sektörü, yakıt kullanımı ve trafik yoğunluğunun değişimi olarak ele alınmıştır. Kent merkezinin nüfus yoğunluğunun 2010 yılından 2019 yılına kadar giderek arttığı tespit edilmiştir. Büyükşehir statüsündeki bir kent için beklenen nüfus artışına yönelik bu değişimin hava kalitesinin değişimine etkisi istasyon verileri ile değerlendirilmiştir. Sanayi sektöründe 2016 yılına kadar sanayi tesisi sayısında artış gözlenirken daha sonraki yıllarda yeni açılan sanayi tesisi sayısında bir azalma tespit edilmiştir. Yakıt kullanımı değişiminde ise 2015 yılı yakıt kullanımının en fazla arttığı yıl olarak belirlenmiştir. Taşıt kullanımında ise 2015 ve 2016 yılında diğer yillara oranla en yüksek artış gerçekleşmiştir.



**Şekil 6.** Kayseri kent merkezinin yıllara göre mevcut durum analizi



**Şekil 7.** 2010, 2015 ve 2019 yıllarına göre PM<sub>10</sub> hava kalitesi değişiminin mekânsal dağılımı

Şekil 7'ye göre mekânsal değişimi izlenen 2010, 2015 ve 2019 yılları arasında PM<sub>10</sub> konsantrasyon miktarının en yüksek olan yılın 2015 yılı olduğu tespit edilmiştir. Analiz sonuçları konumsal değişim ve mevcut durum analizlerine göre incelenmiştir. Buna göre 2010 ve 2015 yılında kentin en eski yerleşim noktası olan Hürriyet ve Trafik İstasyonları yoğun bir hava kirliliği içinde bulunmaktadır. Hürriyet istasyonu bu yıllarda diğer tüm istasyonlardan daha fazla hava kirliliği etkisi altındadır. 2019

yılında ise bu yoğunluğun kent merkezinden OSB'ne doğru konum değiştirdiği görülmektedir. Bunun nedeni 2016 yılından sonra azalan yakıt ve taşit kullanımının bu bölgede yer alan istasyonlardaki (Hürriyet ve Trafik) konsantrasyon miktarlarında azalmaya neden olmasıdır. Ayrıca 2016 yılından sonra kente sanayi sektöründe yıllara göre yeni bir artıya geçilmiş olması OSB bölgesinde hava kirliliğini artırmış ve bu nedenle hava kirliliğinin odak

noktası kent merkezinden OSB bölgесine konum değiştirmiştir.

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

Yapılan bu çalışmaya benzer olarak Tayvan'da Chang vd., (2020) tarafından yapılan çalışmada görünür iki boyutlu topolojik haritada uzun süreli bölgесel PM<sub>2.5</sub> konsantrasyon tahmini için bir makine öğrenmesi modeli oluşturulmuştur. 25 istasyondan çeşitli zaman ölçeklerinde (yıllık, mevsimsel, saatlik) PM<sub>2.5</sub> konsantrasyon verilerini kullanmışlardır. Sonuç olarak nüfus ve trafik yoğunluğu ve mevsimsel değişikliklerin PM<sub>2.5</sub> konsantrasyon değişiminde etkisi olduğunu ortaya koymuşlardır. Makine öğrenmesi tekniklerinin PM<sub>2.5</sub> özelliklerini mükemmel özetleyebildiği ve hava kalitesi tahmin doğruluğunu artırabildiğini belirtmişlerdir [50].

#### **4.Sonuç**

Yapılan çalışma kapsamında;

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

Bu kapsamında Kayseri İli Trafik, OSB, Hürriyet bölgeleri için 2010-2018 yılları arasındaki yıllık PM<sub>10</sub> konsantrasyon verileri kullanılarak 2019 yılına ait hava kirliliği tahmini yapılmıştır. 3 istasyondan 2010-2018 yılları arasında PM<sub>10</sub> konsantrasyonu verileri kullanılarak makine öğrenmesi algoritmaları (kNN DVR, RF, ANN, Lineer Regresyon) ile veriler eğitilmiş her bölgenin 2019 yılına ait tahmini, gerçek verileri verilmeden diğer bölgelerin 2019 verileri kullanılarak elde edilmiştir. Bu şekilde bölgесel bağımlılık elde edilerek geleceğe yönelik tahmin yapılmıştır. Bu amaçla makine öğrenmesi algoritmaları olan DVR, Rastgele Orman, kNN, ANN algoritmaları tarafından üretilmiş olan

tahmin modelleri kullanılmış ve model sonuçları karşılaştırılmıştır. Elde edilen sonuçlara göre hava kirliliği tahmini için en yüksek performansı üç istasyon için de DVR algoritması vermiştir. Modeller karşılaştırıldığında ise en iyi performans Trafik bölgesi için DVR algoritması ( $R^2=0.85$ , RMSE=17.57, MAE=10.17) ile sağlanmıştır. Ayrıca algoritmaların tahmin sonuçları ile gerçek değerler karşılaştırıldığı zaman, tüm algoritmaların genel olarak iyi sonuçlar ürettiğidiler ve gerçek değerlere yakın tahminlerde bulundukları görülmüştür. Uygulanan algoritmalar ile veri setinde büyük veri ile birlikte çok sayıda özellik bulunuyorsa ve bunları yorumlayacak denklem ya da fonksiyon yok ise anlam çıkarmak veya çeşitli sebeplerden dolayı istasyonlarda ölçümelerin eksik olması, kayıp değerlerin olması durumunda veri setindeki kayıp değerler için o niteliğe ait ortalama değerlerle doldurulması sağlanmaktadır. Bunun için çözülmesi gereken problemi çözerken doğru veri ile algoritmayı beslemek çok önemlidir.

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

Kayseri İl'inde hava kirliliği kaynakları özellikle kış aylarında kırsal kesimin konutlarda isınma amaçlı olarak yakılan kalitesiz kömür, motorlu taşılardan kontrolden olarak yayılan salımlar ve OSB bölgesinde faaliyet gösteren sanayi tesislerinin çıktıığı emisyonlardır. Özellikle kırsal kesimlerde yoğun olarak kullanılan fosil yakıtların yerine doğalgaz ya da yenilenebilir enerji kaynaklarının kullanımının teşvik edilmesi, kentleşme ve düzenlilaşmanın bir plan dahilinde yapılması, yeşil alanların artırılması, sanayi tesislerinde emisyon değerlerine sıkı denetimler getirilmesi bu düzenlemeler arasında sıralanabilir. Yapılan bu çalışma, yüksek yoğunluklu kentlerin hava kalitesinin makine öğrenmesi algoritmaları ile

modellenmesi ve hava kalitesini etkileyen arazi kullanımının sürdürülebilir planlanmasına ilişkin öneriler sunması ile literatüre katkı sağlamaktadır.

### Kaynaklar

- [1] A. Alkan, Hava Kirliliğinin Ciddi Boyutlara Ulaştığı Kentlere Bir Örnek: An Example of Cities Where Air Pollution Has Reached Serious Dimensions : Siirt, (2018) 641–666.
- [2] Y. DOKUZ, A. BOZDAĞ, B. GÖKÇEK, HavKalitesiParametreleriniTahmini Ve Mekansal DağılımlıçınMakineÖgrenmesiYöntemlerinin Kullanılması, Ömer Halisdemir Üniversitesi Mühendislik Bilim. Derg. 9 (2020) 37–47. <https://doi.org/10.28948/ngumuh.654092>.
- [3] G.C. SÜMER, Hava Kırılığı Kontrolü: Türkiye'de Hava Kirliliğini Önlemeye Yönelik Yasal Düzenleme-rein ve Örgütlenmelerin İncelenmesi, Uluslararası İktisadi ve İdari İncelemeler Derg. 13 (2014) 37. <https://doi.org/10.18092/ijea.51643>.
- [4] A. Rahimpour, J. Amanollahi, C.G. Tzanis, Air quality data series estimation based on machine learning approaches for urban environments, *Air Qual. Atmos. Heal.* 14 (2021) 191–201. <https://doi.org/10.1007/s11869-020-00925-4>.
- [5] C. Amuthadevi, D.S. Vijayan, V. Ramachandran, Development of air quality monitoring (AQM) models using different machine learning approaches, *J. Ambient Intell. Humaniz. Comput.* (2021). <https://doi.org/10.1007/s12652-020-02724-2>.
- [6] H. Tian, Y. Zhao, M. Luo, Q. He, Y. Han, Z. Zeng, Estimating PM2.5 from multisource data: A comparison of different machine learning models in the Pearl River Delta of China, *Urban Clim.* 35 (2021) 100740. <https://doi.org/10.1016/j.ulclim.2020.100740>.
- [7] Y. Son, Á.R. Osornio-vargas, M.S.O. Neill, P. Hystad, J.L. Texcalac-sangrador, P. Ohman-strickland, Q. Meng, S. Schwander, Land use regression models to assess air pollution exposure in Mexico City using fine spatial and temporal input parameters, *Sci. Total Environ.* 639 (2018) 40–48. <https://doi.org/10.1016/j.scitotenv.2018.05.144>.
- [8] Y. Xu, H. Liu, Z. Duan, A novel hybrid model for multi-step daily AQI forecasting driven by air pollution big data, *Air Qual. Atmos. Heal.* 13 (2020) 197–207. <https://doi.org/10.1007/s11869-020-00795-w>.
- [9] S. Van Roode, J.J. Ruiz-Aguilar, J. González-Enrique, I.J. Turias, An artificial neural network ensemble approach to generate air pollution maps, *Environ. Monit. Assess.* 191 (2019). <https://doi.org/10.1007/s10661-019-7901-6>.
- [10] J.Y. Yang, W.F. Ip, C.M. Vong, P.K. Wong, Effect of choice of kernel in support vector machines on ambient air pollution forecasting, *Proc. 2011 Int. Conf. Syst. Sci. Eng. ICSSE 2011.* (2011) 552–557. <https://doi.org/10.1109/IC SSE.2011.5961964>.
- [11] W. Lu, W. Wang, A.Y.T. Leung, S.M. Lo, R.K.K. Yuen, Z. Xu, H. Fan, Air pollutant parameter forecasting using support vector machines, *Proc. Int. Jt. Conf. Neural Networks.* 1 (2002) 630–635. <https://doi.org/10.1109/ijcnn.2002.1005545>.
- [12] A. Sotomayor-Olmedo, M.A. Aceves-Fernández, E. Gorrostieta-Hurtado, C. Pedraza-Ortega, J.M. Ramos-Arreguin, J.E. Vargas-Soto, Forecast Urban Air Pollution in Mexico City by Using Support Vector Machines: A Kernel Performance Approach, *Int. J. Intell. Sci.* 03 (2013) 126–135. <https://doi.org/10.4236/ijis.2013.33014>.
- [13] H. Sun, D. Gui, B. Yan, Y. Liu, W. Liao, Y. Zhu, C. Lu, Assessing the potential of random forest method for estimating solar radiation using air pollution index, *Energy Convers. Manag.* 119 (2016) 121–129. <https://doi.org/10.1016/j.enconman.2016.04.051>.
- [14] D. Kumar, ScienceDirect Evolving Differential evolution method with random forest for Evolving Differential evolution method with random forest for prediction of Air Pollution prediction of Air Pollution, *Procedia Comput. Sci.* 132 (2018) 824–833. <https://doi.org/10.1016/j.procs.2018.05.094>.
- [15] C. Gariazzo, G. Carlini, C. Silibello, M. Renzi, S. Finardi, N. Pepe, P. Radice, F. Forastiere, P. Michelozzi, G. Viegi, M. Stafoggia, A multi-city air pollution population exposure study: Combined use of chemical-transport and random-Forest models with dynamic population data, *Sci. Total Environ.* 724 (2020) 138102. <https://doi.org/10.1016/j.scitotenv.2020.138102>.
- [16] M.D. Mallet, Meteorological normalisation of PM10 using machine learning reveals distinct increases of nearby source emissions in the Australian mining town of Moranbah, *Atmos. Pollut. Res.* (2020) 0–1. <https://doi.org/10.1016/j.apr.2020.08.001>.
- [17] V. Chaudhary, A. Deshbhratar, V. Kumar, D. Paul, Time Series Based LSTM Model to Predict Air Pollutant's Concentration for Prominent Cities in India, *Udm'18.* (2018).
- [18] C. Wen, S. Liu, X. Yao, L. Peng, X. Li, Y. Hu, T. Chi, A novel spatiotemporal convolutional long short-term neural network for air pollution prediction, *Sci. Total Environ.* 654 (2019) 1091–1099. <https://doi.org/10.1016/j.scitotenv.2018.11.086>.
- [19] Z. Qin, C. Cen, X. Guo, Prediction of Air Quality Based on KNN-LSTM, *J. Phys. Conf. Ser.* 1237 (2019). <https://doi.org/10.1088/1742-6596/1237/4/042030>.
- [20] A. Marjovi, A. Arfire, A. Martinoli, High resolution air pollution maps in urban environments using mobile sensor networks, *Proc. - IEEE Int. Conf. Distrib. Comput. Sens. Syst. DC OSS 2015.* (2015) 11–20. <https://doi.org/10.1109/DC OSS.2015.32>.
- [21] F. Taşpinar, Improving artificial neural network model predictions of daily average PM10 concentrations by applying principle component analysis and implementing seasonal models, *J. Air Waste Manag. Assoc.* 65 (2015) 800–809. <https://doi.org/10.1080/10962247.2015.1019652>.
- [22] B. Choubin, M. Abdolshahnejad, E. Moradi, X. Querol, A. Mosavi, S. Shamshirband, P. Ghamisi, Spatial hazard assessment of the PM10 using machine learning models in Barcelona, Spain, *Sci. Total Environ.* 701 (2020) 134474. <https://doi.org/10.1016/j.scitotenv.2019.134474>.
- [23] E. Sharma, R.C. Deo, R. Prasad, A. V. Parisi, A hybrid air quality early-warning framework: An hourly forecasting model with online sequential extreme learning machines and empirical mode decomposition algorithms, *Sci. Total Environ.* 709 (2020) 135934. <https://doi.org/10.1016/j.scitotenv.2019.135934>.

- [24] M. Stafoggia, T. Bellander, S. Bucci, M. Davoli, K. De Hoogh, F. De Donato, C. Garazzzo, A. Lyapustin, P. Michelozzi, M. Renzi, M. Scorticchini, A. Shtain, G. Viegi, I. Kloog, J. Schwartz, Estimation of daily PM 10 and PM 2 . 5 concentrations in Italy , 2013 – 2015 , using a spatiotemporal land-use random-forest model, Environ. Int. 124 (2019) 170-179. <https://doi.org/10.1016/j.envint.2019.01.016>.
- [25] A. Ertürk, A. Ekdal, M. Gurel, K. Yuceil, A. Tanik, Use of mathematical models to estimate the effect of nutrient loadings on small streams, Fresen. Environ. Bull. 13 (2004) 1361-1370.
- [26] M. ATAOL, Burdur Gölü'nde Seviye Değişimleri, Co. 8 (2010) 077-092. [https://doi.org/10.1501/cogbil\\_0000000105](https://doi.org/10.1501/cogbil_0000000105).
- [27] T. Yomralioğlu, Coğrafi Bilgi Sistemleri: Temel Kavamlar ve Uygulamalar, Seçil Ofset, İstanbul, 2000.
- [28] S. İncekara, M. Karakuyu, A. Karaburun, ORTAÖĞRETİM CoğrafyaDerslerinde Yaparak Öğrenmeye Bir Örnek:CoğrafıBilgSistemlerinin ProjeTemelliÖğrenimde Kullanılması, Elektron. Sos. Bilim. Derg. 8 (2009) 305-322. <https://doi.org/10.17755/esosder.76302>.
- [29] E. Kapluhan, COĞRAFI BİLGİ SİSTEMLERİNİN(CBS) COĞRAFYA ÖĞRETMİNDE KULLANIMININ ÖNEMİ VE GEREKLİLİĞİ, MARMARA COĞRAFYA DERGİSİ. 29 (2014) 34-59.
- [30] C. Güney, Mekansal zekanın getirdiği paradigma değişimi, J. Geod. Geoinf. 6 (2019) 128-142. <https://doi.org/10.9733/jgg.2019r0006.t>.
- [31] W.J. Requia, B.A. Coull, P. Kourakis, Evaluation of predictive capabilities of ordinary geostatistical interpolation , hybrid interpolation , and machine learning methods for estimating PM 2 . 5 constituents over space, Environ. Res. 175 (2019) 421-433. <https://doi.org/10.1016/j.envres.2019.05.025>.
- [32] C.C. Lim, H. Kim, M.J.R. Vilcassim, G.D. Thurston, T. Gordon, L. Chen, K. Lee, M. Heimbinder, S. Kim, Mapping urban air quality using mobile sampling with low-cost sensors and machine learning in Seoul , South Korea, Environ. Int. 131 (2019) 105022. <https://doi.org/10.1016/j.envint.2019.105022>.
- [33] ÇED ve Çevre İzinleri Şube Müdürlüğü, Çevre ve Şehircilik İl Müdürlüğü Kayseri İli 2018 Yılı Çevre Durum Raporu, (2019).
- [34] G.H. Marks Hall, WEKA: Practical Machine Learning Tools and Techniques with Java Implementations, (1994). <https://researchcommons.waikato.ac.nz/bitstream/handle/10289/1040/uow-cs-wp-1999-11.pdf?sequence=1&isAllowed=y>.
- [35] M. Yilmaz, R. Kanit, M. Erdal, S. Yildiz, A. Bakış, K.H. Okulu, I.M. Bölümü, Bina Bakım Onarım Ödenekelarının Etkin Kullanımı Maksadıyla İhale Bedelini Etkileyen Faktörlerin Yapay Sinir Ağları ve Lineer Regresyon Yöntemleri ile Belirlenmesi Determination of The Factors Effecting The Tender Price by way of Artificial Neural Networks, 19 (2016) 461-470.
- [36] H. Drucker, C.J.C. Burges, L. Kaufman, A. Smola, V. Vapoik, W. Long, B. Nj, Support Vector Regression Machines w ) tw , 1 (n.d.).
- [37] L.E.O. Breiman, Random Forests, (2001) 5-32.
- [38] B. Lantz, Machine Learning with R, Packt Publishing Ltd, UK, 2013.
- [39] A. Jain, J. Mao, Artifical Neural Networks: A Tutorial., Comput. (Long. Beach. Calif). 29 (1996) 31-44.
- [40] J.Y. Son, M.L. Bell, J.T. Lee, Individual exposure to air pollution and lung function in Korea: Spatial analysis using multiple exposure approaches, Environ. Res. 110 (2010) 739-749. <https://doi.org/10.1016/j.envres.2010.08.003>.
- [41] M. Wu, J. Huang, N. Liu, R. Ma, Y. Wang, L. Zhang, A Hybrid Air Pollution Reconstruction by Adaptive Interpolation Method, in: Proc. 16th ACM Conf. Embed. Networked Sens. Syst., 2018: pp. 408-409.
- [42] W.J. Requia, M.D. Adams, A. Arain, S. Papatheodorou, P. Kourakis, M. Mahmoud, Global Association of Air Pollution and Cardiorespiratory Diseases: A Systematic Review, Meta-Analysis, and Investigation of Modifier Variables, Am. J. Public Health. 108 (2018) S123-S130. <https://doi.org/10.2105/AJPH.2017.303839>.
- [43] K. Shukla, P. Kumar, G.S. Mann, M. Khare, Mapping spatial distribution of particulate matter using Kriging and Inverse Distance Weighting at supersites of megacity Delhi, Sustain. Cities Soc. 54 (2020) 101997. <https://doi.org/10.1016/j.scs.2019.101997>.
- [44] A. Bozdağ, Y. Dokuz, Ö.B. Gökcük, Spatial prediction of PM10 concentration using machine learning algorithms in Ankara, Turkey, Environ. Pollut. 263 (2020). <https://doi.org/10.1016/j.envpol.2020.114635>.
- [45] Url, Kayseri İl Kültür ve Turizm Müdürlüğü, (2020). <https://kayseri.ktb.gov.tr/TR-54966/cografi-yapi.html>.
- [46] M. Ashayeri, N. Abbasabadi, M. Heidarnejad, B. Stephens, Predicting intraurban PM2.5 concentrations using enhanced machine learning approaches and incorporating human activity patterns, Environ. Res. (2020) 110423. <https://doi.org/10.1016/j.envres.2020.110423>.
- [47] M. Lovrić, K. Pavlović, M. Vuković, S.K. Grange, M. Haberl, R. Kern, Understanding the true effects of the COVID-19 lockdown on air pollution by means of machine learning, Environ. Pollut. (2020). <https://doi.org/10.1016/j.envpol.2020.115900>.
- [48] S. Kumar, S. Mishra, S.K. Singh, A machine learning-based model to estimate PM2.5 concentration levels in Delhi's atmosphere, Heliyon. 6 (2020) e05618. <https://doi.org/10.1016/j.heliyon.2020.e05618>.
- [49] A.O. Karababa, B. ATLI, Ç. Çağlayan, G. Varol, G. Ersoy, F. Gacal, N. Etiler, P. Özfirat, S. Ayta, Kara Rapor 2020: Hava Kirliliği ve Sağlık Etkileri, Temiz Hava Hakkı Platformu. (2020). <https://www.temizhavahakkı.com/kara-rapor/>.
- [50] F.J. Chang, L.C. Chang, C.C. Kang, Y.S. Wang, A. Huang, Explore spatio-temporal PM2.5 features in northern Taiwan using machine learning techniques, Sci. Total Environ. 736 (2020) 139656. <https://doi.org/10.1016/j.scitotenv.2020.139656>.