

# Yapay Zekâ Tabanlı Hava Kalitesi İyileştirme Stratejilerinin Değerlendirilmesi

## Evaluation of Artificial Intelligence-Based Air Quality Improvement Strategies

 Tugce Pekdogan<sup>1</sup>

<sup>1</sup> Doktor Öğretim Üyesi, Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Mimarlık ve Tasarım Fakültesi, Mimarlık Bölümü, Çukurova/Adana  
tpekdogan@atu.edu.tr

### Özet

Günümüzde hava kirliliği, kentsel ve sanayi bölgelerinde yaşayan milyonlarca insan için ciddi sağlık riskleri oluşturmaktadır. Bu makalede, yapay zekâ (AI) teknolojileri ve makine öğrenimi algoritmalarının hava kalitesini izleme ve iyileştirme stratejilerinin geliştirilmesinde nasıl kullanılabileceği ele alınmıştır. Bu araştırma, özellikle kentsel alanlarda hava kalitesi üzerinde etkili olan ana kirleticilerin dinamiklerini modellemek için makine öğrenmesi yaklaşımlarını kullanmaktadır.

Bu çalışmada, çeşitli yapay zekâ modelleri (RF, SVM, ANN, CNN, RNN, GAN) kullanılarak hava kalitesi verilerinin analiz, tahmin ve simüle edilmesi süreçleri detaylı bir şekilde incelenmiştir. Ayrıca, bu modellerin hava kalitesi yönetimi için stratejik karar verme süreçlerinde nasıl entegre edilebileceği üzerinde durulmuştur. Yapay zekâ tabanlı modeller, gerçek zamanlı veri akışını analiz ederek, hava kalitesi üzerinde olumlu etkiler yaratabilecek müdahaleler önermektedir.

Anahtar Kelimeler: Hava Kalitesi, Derin Öğrenme, Yapay Zekâ, Makine Öğrenmesi, Yapay Sinir Ağları.

### Abstract

Today, air pollution causes serious health risks for millions living in urban and industrialized areas. This paper discusses how artificial intelligence (AI) technologies and machine learning algorithms can be used to develop air quality monitoring and improvement strategies. This research uses machine learning approaches to model the dynamics of the main pollutants that influence air quality, especially in urban areas.

In this study, the processes of analyzing, predicting and simulating air quality data using various artificial intelligence models (RF, SVM, ANN, CNN, RNN, GAN) are examined in detail. Furthermore, how these models can be integrated into strategic decision-making processes for air quality management is emphasized. By analyzing the real-time data flow, AI-based models suggest interventions that can positively impact air quality.

Keywords: Air Quality, Deep Learning, Artificial Intelligence, Machine Learning, Artificial Neural Networks.

## 1. Giriş

Hava kirliliği, dünya çapında büyük bir çevresel ve sağlık sorunu olarak öne çıkmaktadır. Kentleşme ve sanayileşme, hava kalitesi sorunlarını daha da artırmaktadır. Çin'in büyük şehirlerinde PM2.5 seviyeleri, Dünya Sağlık Örgütü'ne (WHO)'nun belirlediği sınır değerlerinin çok üzerinde olup ciddi sağlık riskleri yaratmaktadır [1]. Hindistan'da da benzer şekilde, yüksek hava kirliliği seviyeleri milyonlarca erken ölüme neden olmaktadır [2]. Gelişmiş ülkelerde bile, hava kirliliği önemli bir halk sağlığı sorunu olmaya devam etmektedir [3]. WHO'ya göre, her yıl yaklaşık 7 milyon insan hava kirliliğine bağlı hastalıklar nedeniyle yaşamını yitirmektedir [4]. Hava kirliliği, özellikle PM2.5 ve PM10 gibi ince partiküller, astım, bronşit ve diğer solunum yolu hastalıklarının yanı sıra kalp hastalıkları ve felç gibi ciddi sağlık problemlerine neden olmaktadır [5]. Ayrıca, çocuklar, yaşlılar ve kronik hastalığı olan bireyler gibi savunmasız gruplar, hava kirliliğinden daha fazla etkilenmektedir [6]. Hava kirliliğinin insan sağlığı üzerindeki zararlı etkileri birçok çalışmada tartışılmaktadır. PM10 öncelikle üst solunum yollarında birikir. Bununla birlikte, ince (PM2.5 ve PM1, çapı 2.5'ten küçük ve sırasıyla 1µm'den küçük parçacıkları oluşturur) ve ultra ince (PM0.1) parçacıklar akciğer alveollerine ulaşabilir [5], [7]. Kardiyovasküler [8], [9] ve solunum [10], [11] etkileri ile ilgili olarak, ince ve ultra ince parçacıklar PM10'dan daha tehlikelidir [12]. İnsan sağlığı üzerindeki etkiler mide bulantısından [13] nefes almada zorluğa [14] ve akciğer kanserine [15] kadar değişebilir.

Avrupa Birliği, Avrupa'yı 2050 yılına kadar net sera gazı emisyonu olmayan ilk kıta yapmak için 2030 yılına kadar net sera gazı emisyonlarını 1990 seviyelerine kıyasla en az %55 oranında azaltmayı hedefleyen Avrupa Yeşil Anlaşması'nı imzalamıştır. Böylece, 2050 için hava, su ve toprak kirliliğini insan sağlığı ve ekolojik sistemler için tehlikeli sayılmayan seviyelere düşürme hedefi belirlenen bu anlaşma ile çevresel hedeflere önemli ölçüde katkıda bulunacağı ön görülmektedir [16].

Halk sağlığına etkisinin yanı sıra hava kirliliğinin ekonomik maliyetleri de oldukça yüksektir. OECD'nin raporuna göre, hava kirliliği küresel ekonomiye her yıl trilyonlarca dolara mal olmaktadır [17]. Bu maliyetler, sağlık harcamaları, iş gücü kaybı ve üretim düşüşlerini içermektedir. Ekolojik açıdan bakıldığında, hava kirliliği bitki örtüsünü tahrip etmekte, su kaynaklarını kirletmekte ve biyolojik çeşitliliği azaltmaktadır [18]. Kentsel ve sanayi bölgeleri, hava kirliliğinin yoğun olarak görüldüğü alanlardır. Kentsel alanlarda, trafik yoğunluğu ve sanayi faaliyetleri, hava kirliliğinin başlıca kaynaklarını oluşturur. Şehirlerde artan motorlu taşıt sayısı, egzoz gazları yoluyla atmosfere zararlı maddelerin salınmasına neden olmaktadır [19]. Sanayi bölgelerinde ise fabrikalar ve enerji santralleri, sülfür dioksit (SO<sub>2</sub>), karbon monoksit (CO) ve uçucu organik bileşikler (VOC) gibi kirleticileri atmosfere salar [20]. Bu kirleticiler, sadece yerel hava kalitesini düşürmekle kalmaz, aynı zamanda uzun mesafeler kat ederek geniş alanlarda kirliliğe yol açar.

Bu nedenle hava kalitesini iyileştirmenin ilk ve en önemli adımı, düzenli olarak hava kalitesi ölçümlerinin yapılması ve mevcut durumu doğru bir şekilde tespit edilmesidir. Bu ölçümler, kentsel ve endüstriyel alanlarda hava kirliliğinin seviyesini ve kaynaklarını belirlemek için kritik bir rol oynamaktadır. Hava kalitesi sensörleri ve izleme istasyonları, partikül madde (PM2.5, PM10), ozon (O<sub>3</sub>), azot dioksit (NO<sub>2</sub>), kükürt dioksit (SO<sub>2</sub>) ve karbon monoksit (CO) gibi kirleticilerin

konsantrasyonlarını belirlemektedir. Bu veriler, hava kirliliği seviyelerindeki değişimleri izlemek, kirlilik kaynaklarını tespit etmek ve bu kaynakların etkilerini değerlendirmek için kullanılır. Elde edilen veriler, çevre politikalarının geliştirilmesi, acil durum müdahalelerinin planlanması ve halk sağlığını koruyacak stratejilerin oluşturulması için önemli bir temel sağlar.

Günümüzde yapay zekâ ve makine öğrenimi teknolojileri, hava kalitesi analizinde ve iyileştirilmesinde büyük bir potansiyele sahiptir. Bu teknolojiler, büyük veri kümelerini işleyerek ve modelleyerek hava kalitesi tahminlerinde yüksek doğruluk sağlarlar. Yapay zekâ, hava kirliliği kaynaklarını belirleme, kirlilik seviyelerini tahmin etme ve iyileştirme stratejileri geliştirme süreçlerinde kritik bir rol oynar [21]. Ülkemizde, T.C. Çevre ve Şehircilik Bakanlığı tarafından kurulan "Ulusal Hava Kalitesi İzleme Ağı" (UHKİA) hava kalitesini sürekli olarak izleyerek, hava kirliliği seviyelerini ve kaynaklarını belirlemekte ve bu verileri kullanarak iyileştirme stratejileri geliştirmektedir. UHKİA'nın faaliyetleri kapsamında, çok kriterli karar verme (multi-criteria decision making-MCDM) ve yapay zekâ teknikleri kullanılarak, hava kalitesi yönetiminde daha etkili ve verimli kararlar alınması sağlanmaktadır [22].

Yapay zekâ tabanlı yaklaşımlar, hava kalitesi izleme ağlarından gelen verileri analiz ederek gerçek zamanlı tahminler yapabilmektedir. Literatürde Random Forests (RF), Support Vector Machines (SVM), Artificial Neural Networks (ANN), Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), ve Generative Adversarial Networks (GAN) gibi farklı yapay zekâ modelleri kullanılarak karmaşık hava kalitesi verilerini işlenmiştir.

Bu çalışmanın amacı, literatürdeki yapay zekâ tabanlı hava kalitesi iyileştirme stratejilerini incelemek ve bu alandaki uygulamaları değerlendirmektir. Çalışma, yapay zekâ ve makine öğrenimi teknolojilerinin hava kalitesi analizindeki rolünü, çeşitli modellerin performansını ve farklı yaklaşımların etkinliğini ele alacaktır. Özellikle, bu çalışmada irdelenmiş olan hibrit yapay zekâ modelleri ve büyük veri kümelerinin entegrasyonu gibi yenilikçi yaklaşımlar, mevcut literatüre önemli katkılar sağlamaktadır. Ayrıca, hava kalitesi yönetimi ve iyileştirme stratejileri için yapay zekâ tabanlı çözümlerin potansiyeli ve gelecekteki araştırma alanları tartışılacaktır.

## 2. Yapay Zekâ Modelleri ve Hava Kalitesi

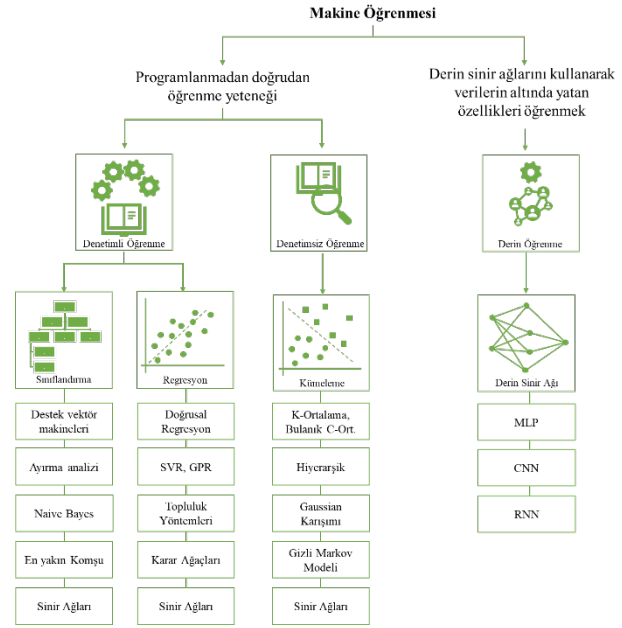
Yapay zekâ ile hava kalitesi tahmini yapan birçok çalışma bulunmaktadır. Yapay zekânın hava kalitesi izleme sistemlerine dahil edilmesi birçok sektörde yaygın olarak kullanılmakta ve büyük avantajlar sağlamaktadır. Bu sistemler, şehir planlama, halk sağlığı, sanayi ve tarımda hava kalitesini izlemek ve yönetmek için gerekli verileri sağlamaktadır. Kentsel planlamada, yapay zekâ modelleri kullanılarak hava kalitesi haritaları oluşturulmakta ve kirlilik kaynakları belirlenmektedir. Bu tür uygulamalar, kentsel alanlarda hava kalitesini iyileştirme çabalarına büyük katkı sağlamaktadır. Pekdoğan vd. [16] tarafından yapılan çalışmada Adana'da 3 farklı sensör aracılığıyla il bazında kirlilik tespit edilmiştir. Şehirlerdeki hava kalitesini takip eden bu sistemler, kullanıcıların bu verilerle anlık olarak etkileşime geçmesini de sağlamaktadır. Bu uygulamalar, bireylerin günlük aktivitelerini hava kalitesine göre planlamalarına ve kirlilik konusunda farkındalık kazanmalarına yardımcı olmaktadır. Başka bir kentsel bağlamda yapılmış olan çalışmada ise; yapay zekâ tabanlı optimizasyon algoritmaları, trafik yönetimi ve

endüstriyel emisyon kontrolü gibi alanlarda hava kalitesini iyileştirme stratejileri geliştirmek için kullanılmaktadır [23]. Bu stratejiler, hava kirliliği seviyelerini düşürmeye yönelik pratik çözümler sunar. Endüstriyel tesislerde ise hava kalitesi izleme sistemleri emisyonları izlemek ve mevcut politika ve düzenlemelere uymak için kullanılır. Bu sistemler, emisyonları en aza indirmek ve çevresel etkileri azaltmak için gerçek zamanlı veriler sağlar. Bu teknolojiler, özellikle kimya, petrol ve gaz endüstrileri gibi yüksek emisyonlu sektörlerde kritik öneme sahiptir [20]. Ayrıca hava kalitesi izleme sistemleri, halk sağlığını tehdit eden unsurların tespit edilebilmesi için öneme sahiptir. Makine öğrenmesi algoritmaları ile hava kirliliği seviyelerindeki değişimler tahmin edilebilir ve bu tahminlere göre önleyici tedbirler politika yapıcılar tarafından alınabilir [24]. Yapay zekâ tabanlı hava kalitesi izleme sistemleri, tarım alanlarında da oldukça büyük bir yer edinmiştir. Özellikle Tarım 4.0 dönüşümü ile bilgisayar destekli kontrol sistemleri, çeşitli yazılım ve donanım araçları, dijital sensörlerle donatılmış tarım makineleri, görüntü işleme teknolojileri gibi akıllı sistemlerin kurulması ve yaygınlaştırılması son derece önemli hale gelmiştir [25]. Bu tip hava kalitesi izleme sistemleri akıllı tarımda çeşitli kirlenmelerin ve çevresel parametrelerin izlenmesini sağlar. Bu sistemler, bitkilerin büyüme koşullarını optimize etmek ve çevresel stres faktörlerini en aza indirmek için kullanılır [26].

## 2.1. Yapay Zekâ ve Makine Öğrenimi Temelleri

Yapay zekâ ve makine öğrenimi, büyük veri kümelerini analiz etmek ve tahminler yapmak için kullanılan güçlü teknolojilerdir. Bu teknolojiler, veri toplama, işleme ve modelleme süreçlerinde kullanılarak hava kalitesi tahminlerinde yüksek doğruluk sağlar. Yapay zekâ, karmaşık veri yapılarını analiz ederek hava kirliliği seviyelerini tahmin etme, kirlilik kaynaklarını belirleme ve iyileştirme stratejileri geliştirme süreçlerinde önemli bir rol oynar [27].

Makine öğrenimi, özellikle büyük veri analizinde etkili olan algoritmalar kullanarak hava kalitesi tahminlerinde doğruluğu artırmaktadır. Bu algoritmalar, tarihsel verileri kullanarak gelecekteki kirlilik seviyelerini tahmin edebilir ve böylece hava kalitesi yönetiminde proaktif önlemler alınmasına olanak tanır [28]. Şekil 1 makine öğrenmesi algoritmalarını ve bunların kategorilerini göstermektedir. Şekil üç ana bölüme ayrılmıştır: Denetimli Öğrenme, Denetimsiz Öğrenme ve Derin Öğrenme [29]. Denetimli öğrenme, etiketlenmiş veriler kullanılarak modellerin eğitildiği bir öğrenme yöntemidir. Bu kategoride, Destek Vektör Makineleri (SVM), En Yakın Komşu (KNN), Sinir Ağları, doğrusal regresyon, destek vektör regresyonu (SVR), Gaussian süreç regresyonu (GPR), karar ağaçları gibi çeşitli algoritmalar yer almaktadır. Denetimsiz öğrenme, etiketlenmemiş veriler kullanılarak yapılır. Bu kategoride, K-Ortalama, Gaussian Karışımı, Gizli Markov Modeli gibi algoritmalar kullanılmaktadır. Derin öğrenme ise yapay sinir ağları kullanarak daha karmaşık veri işlemleri yapan bir öğrenme yöntemidir. Bu kategoride de Çok Katmanlı Algılayıcılar (MLP), Evrimsel Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN) kullanılmaktadır.



Şekil-1: Yapay zekâ tabanlı makine öğrenmesi ve derin öğrenme teknikleri [29]

## 2.2. Hava Kalitesi Tahmininde Kullanılan Yapay Zekâ Modelleri

Gelişmekte olan ülkelerde kentleşme ve endüstriyel faaliyetler artmaya devam ettikçe, doğru ve güvenilir hava kalitesi tahminlerine duyulan ihtiyaç giderek daha önemli hale gelmektedir. Son yıllarda yapay zekâ tekniklerinin yaygınlaşması, hava kalitesi tahmini alanında da yer edinmiştir. Bu modeller veriye dayalı olmakla birlikte gelişmiş tahmin doğruluğu ve verimliliği sunar. Hava kalitesi tahmininde yaygın olarak kullanılan çeşitli yapay zekâ modelleri bulunmaktadır. Tablo 1 literatürde yer alan farklı modellerin uygulamalarını, amaçlarını ve sonuçlarını vurgulayarak hava kalitesi tahmininde AI teknolojilerinin kullanımına dair genel bir bakış sunmaktadır.

Tablo-1: Hava kalitesi tahmini çalışmaları

Ref.	Konum	Yöntem	Amaç
[30]	Türkiye	ANN	ANN modelleri kullanarak ortam SO <sub>2</sub> seviyelerini tahmin etmek
[31]	Hindistan	ANN	Hava kalitesini tahmin etmek için YSA ve GPR modellerini karşılaştırmak
[32]	Kuveyt	RF	Eksik verileri ele alarak hava kalitesi tahminlerini iyileştirmek
[33]	Tayvan	SVM	Zaman ve mekansal özellikleri kullanarak hava kalitesini tahmin etmek

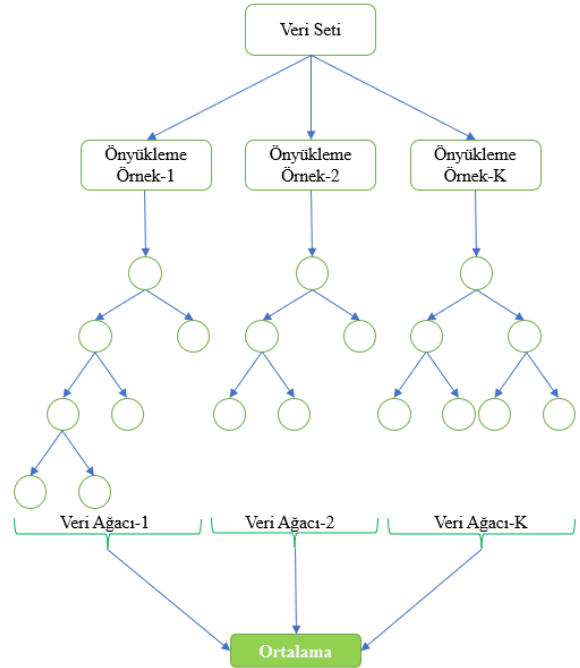
Tablo-1: Hava kalitesi tahmini çalışmaları (devam)

Ref.	Konum	Yöntem	Amaç
[34]	Endonezya	SVM	Hava kalitesini tahmin etmek için SVM ve Karar Ağacı modellerini karşılaştırmak
[35]	Hindistan	SVM, Hibrit	Çeşitli ML algoritmalarını kullanarak hava kalitesini tahmin etmek
[36]	Taipei, Tayvan	SVM, Hibrit	Meteorolojik verileri ve kirlilik kaynaklarını entegre ederek hava kalitesini tahmin etmek
[37]	Uruguay	GAN	Gerçek veri eksikliğini gidermek için sentetik veri üretmek
[38]	Hindistan	CNN, GAN	Farklı modelleri birleştirerek hava kalitesini tahmin etmek

### 2.2.1. Rastgele Orman

Rastgele Orman (RF-Random Forest) modelleri, verilerdeki karmaşık ve doğrusal olmayan ilişkileri ele alma yetenekleri nedeniyle hava kalitesi tahmini için bir araçtır. Bu modeller, düşük maliyetli sensör kalibrasyonu, kentsel hava kalitesi tahmini, iç mekân hava kalitesi izleme ve büyük ölçekli hava kirlenme tahmini dahil olmak üzere çeşitli hava kalitesi tahmin uygulamalarında kullanılır. Zimmerman vd. [39] tarafından yapılan çalışmada, RF modelleri kullanılarak düşük maliyetli hava kalitesi sensörleri için kalibrasyon stratejilerinin geliştirilmiştir. RF modelleri, altı aylık bir süre boyunca CO, NO<sub>2</sub>, CO<sub>2</sub> ve O<sub>3</sub>'ü ölçen birden fazla kirlenme için geliştirilmiş ve doğrulanmıştır. Bu çalışmanın sonucuna göre, RF modellerinin doğruluk ve sağlamlık açısından doğrusal regresyon gibi geleneksel kalibrasyon yöntemlerinden önemli ölçüde daha iyi performans gösterdiğini göstermiştir.

Yu vd. [40] kentsel algılama sistemlerinde hava kalitesi tahmini için kullanmıştır. Bu yaklaşım, hava kalitesini tahmin etmek için meteorolojik veriler, trafik durumu gibi çeşitli veri kaynaklarını kullandı. Bu çalışmaya göre, RF tabanlı modelin, destek vektör makineleri ve çoklu doğrusal regresyon gibi diğer algoritmalarından daha iyi performans göstererek yüksek doğrulukta hava kalitesi tahminleri sağladığı görülmüştür. Alsaber vd. [32] tarafından yapılan çalışmada RF modelleri, Kuveyt genelinde hava kirlenme maddelerinin tahminini geliştirmek ve eksik veri sorunlarını gidermek için kullanılmıştır. Çalışma, RF modellerinin büyük ve çeşitli veri kümelerini işleme konusundaki ve geniş alanlarda gerçek zamanlı hava kalitesi tahmini konusundaki performansını değerlendirmiştir. Şekil 2 Rastgele Orman (RF) modelinin akış şemasını göstermektedir. Bu yöntem ile modelin doğruluğu artırılır ve aşırı öğrenme azaltılır, böylece daha güvenilir ve genelleştirilebilir tahminler elde edilir [41].




Şekil-2: RF Model Mimarisi [41]

### 2.2.2. Destek Vektör Makinesi

Destek Vektör Makinesi (SVM- Support Vector Machines) modellerinin, yüksek boyutlu verileri ve karmaşık ilişkileri ele alma yetenekleri nedeniyle hava kalitesi tahmininde oldukça etkili olduğu kanıtlanmıştır. Bu modeller, geleneksel yöntemlerden ve diğer bazı makine öğrenimi algoritmalarından daha iyi performans göstererek hava kalitesini tahmin etmede yüksek doğruluk göstermektedir. Liu vd. [33] zamansal ve mekansal özellikleri birleştirerek bilinmeyen konumlardaki hava kalitesini tahmin etmek için bu modeli kullanmıştır. Çalışma, yerel verilere dayalı olarak farklı alanlara uyarlanabilecek, kentsel planlama ve hava kalitesi yönetimi çabalarını geliştirebilecek bir tahmin çerçevesi oluşturmuştur.

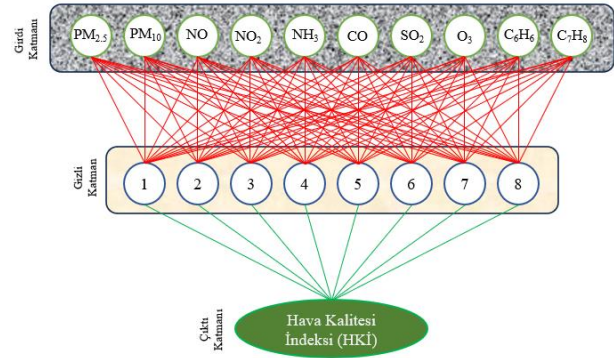
Rafif vd. [34] Jakarta'daki Hava Kalitesi Endeksi'ni tahmin etmek için SVM ve Karar Ağacı algoritmalarını karşılaştırmıştır. Bu model karar ağacı modelinden daha iyi performans göstermiştir. Kumar ve Pande [35] tarafından yapılan çalışmada çeşitli çevresel ve meteorolojik parametreleri birleştirerek Delhi'deki hava kalitesini tahmin etmek için SVM modelleri kullanılmıştır. Sonuç olarak bu model geleneksel yöntemlere göre önemli ölçüde daha iyi, yüksek tahmin doğruluğu sağlamıştır. Liu vd. [33] yapılan bu çalışma meteorolojik verileri ve kirlilik kaynaklarını entegre ederek kentsel ölçekte hava kalitesini tahmin etmek için SVM modellerini kullanmıştır. Gelişmiş tahmin performansı için birden fazla veri kaynağını birleştirmenin önemini vurgulayarak bu model hava kalitesini yüksek doğrulukla etkili bir şekilde tahmin etmiştir. Şekil 3, bir Destek Vektör Makinesi (SVM) mimarisini göstermektedir. Buradaki süreç, SVM'nin veri sınıflandırmasını veya regresyonunu gerçekleştirmesini sağlamaktadır [42].



Şekil-3: SVM Model Mimarisi [42]

### 2.2.3. Yapay Sinir Ağları

Yapay Sinir Ağları (ANN- Artificial Neural Networks): Çeşitli çevresel faktörler ve kirlenici konsantrasyonları arasındaki karmaşık, doğrusal olmayan ilişkileri modelleme yetenekleri nedeniyle hava kalitesi tahmininde kullanılan önemli bir yapay zekâ yöntemidir. Sofuoğlu vd. [30], Türkiye'deki dış ortam SO<sub>2</sub> konsantrasyonlarını tahmin etmek için bir yapay zekâ modeli geliştirdi. Bu çalışma, sınırlı girdi değişkenlerine sahip kentsel ortamlardaki hava kirlenici madde konsantrasyonlarının modellenmesinde bu metodun etkinliğini göstermektedir. Suri vd. [31] Hindistan'ın altı şehrinde hava kalitesi endekslerini tahmin etmek için ANN modellerini kullanmıştır. Bu çalışmaya göre, ANN hava kalitesini tahmin etmede yüksek doğruluk sağlamıştır. Gao vd. [43], ozon konsantrasyonlarını tahmin etmek için Monte Carlo analiziyle birleştirilmiş bir ANN modeli kullanmıştır. Bu yaklaşım ile hem geçmiş hava kalitesi verilerini hem de meteorolojik değişkenleri birleştirilerek tahmin doğruluğunu artırmıştır. Ordieres-Meré vd. [44], ABD-Meksika sınır bölgesindeki ince partikül madde (PM<sub>2.5</sub>) seviyelerini tahmin etmek için ANN modelini kullanmıştır. Bu model, geçmiş verilere dayanarak PM<sub>2.5</sub> konsantrasyonlarını doğru bir şekilde tahmin ederek geleneksel istatistiksel modellerden daha iyi performans göstermiştir. Şekil 4 bir Yapay Sinir Ağı modelinin hava kalitesi indeksini tahmin etme sürecinin örneğidir. Bu yapı, farklı kirlenici konsantrasyonlarından gelen bilgilerin işlenerek tek bir hava kalitesi değerine dönüştürülmesini sağlamaktadır.




Şekil-4: ANN Model Mimarisi [45]

### 2.2.4. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (CNN): CNN'ler, özellikle görüntü ve uzamsal veri analizi için kullanılır. Hava kalitesi tahmininde, uydu görüntülerinden elde edilen veriler CNN'ler ile işlenerek kirlilik seviyeleri tahmin edilebilir. CNN'ler, hava kirliliği haritalarını ve dağılım modellerini oluşturarak, kirlilik kaynaklarının mekansal analizini yapmaktadır. Bu model görüntü ve mekansal veri analizinde oldukça etkilidir ve bu da hava kalitesi tahmini için uygun hale getirir. Bu modeller, kentsel alanlardaki hava kalitesi sorunlarının belirlenmesi ve yönetilmesinde büyük avantaj sağlar. Özellikle CNN'ler, uydu görüntülerinden ve diğer kaynaklardan gelen verileri işleyerek kirlilik seviyelerini tahmin etmek için kullanılmaktadır.


Bai ve Peng [46] tarafından yapılan çalışma, CNN'lerin PM<sub>2.5</sub> konsantrasyonlarını azaltmak için kentsel tasarımı nasıl destekleyebileceğini araştırırken eğitilen bu model ile kentsel tasarım önerilerine dayanarak PM<sub>2.5</sub> konsantrasyonlarının hızlı bir şekilde tahmin edilebilir olmasına olanak tanımıştır. Bu mimari, giriş zaman serisi verileriyle başlar ve özellikleri çıkarmak ve özetlemek için çoklu evrişim ve havuzlama katmanlarından geçirir [47]. Daha sonra veriler düzleştirilir ve nihai tahmini üretmek için tam bağlı bir katmandan geçirilir. CNN mimarisi, sıralı zaman serisi verilerinden kalıpları verimli bir şekilde işlemek ve öğrenmek için tasarlanmıştır, bu da onu hava kalitesi tahmini gibi görevler için uygun kılmaktadır. Bu mimari, verilerdeki yerel örüntüleri ve bağımlılıkları yakalamak için evrişimli katmanların gücünden yararlanırken, havuzlama katmanları veri boyutunu ve hesaplama gereksinimlerini azaltmaya yardımcı olur. Sonundaki tam bağlantılı katman, nihai bir tahmin yapmak için öğrenilen özellikleri sentezlemektedir [48]. Şekil 5 hava kalitesi ve meteorolojik parametreleri kullanarak saatlik hava kalitesi tahmini yapan bir CNN modelinin yapısını göstermektedir. Bu yapı, çeşitli hava kalitesi ve meteorolojik parametreleri işleyerek yüksek doğrulukla hava kalitesi tahminleri yapabilen bir CNN modelinin temel işleyişini göstermektedir [47], [48].



Şekil-5: CNN Model Mimarisi [47], [48]

### 2.2.5. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (RNN): RNN'ler, zaman serisi verilerinin analizi için idealdir. Hava kalitesi tahmininde, geçmiş hava kalitesi verileri kullanılarak gelecekteki kirlilik seviyeleri tahmin edilebilmektedir. Ramachandraarjunan vd. [49] hava kalitesi seviyelerini otomatik olarak tahmin etmek ve havalandırma sistemlerini kontrol etmek için IoT cihazları ve RNN'leri kullanan bir Akıllı İç Hava Kalitesi İzleme sistemi geliştirmiştir. Nurcahyanto vd. [50] ise endüstriyel bir temiz oda ortamında PM10 konsantrasyonlarını tahmin etmek için çok seviyeli bir RNN modeli uygulamıştır. Zhao vd. [51], Amerika Birleşik Devletleri'ndeki üç endüstriyel şehirde günlük Hava Kalitesi Sınıflandırmasını tahmin etmek için derin bir RNN modeli kullanmıştır. Athira vd. [38] meteorolojik ve hava kalitesi verilerini içeren AirNet veri kümesini kullanarak hava kalitesi tahmini için RNN ve uzun kısa süreli bellek (LSTM) modellerini uygulamıştır. [52], yağış ve hava kalitesini tahmin etmek için konvülsiyonel LSTM ile birleştirilmiş RNN'lerin kullanımını araştırmıştır. Çalışma, meteorolojik verilerin RNN modelleriyle entegre edilmesinin hava kalitesi parametrelerinin tahmin doğruluğunu önemli ölçüde artırdığını ortaya koymuştur. Livingston vd. [53] tarafından yapılan bir çalışmada, hava kalitesi tahmini için RNN'leri diğer modellerle birleştiren bir toplu makine öğrenimi yaklaşımı önerilmiştir. Çalışma, modeli test etmek için Pekin'den alınan verileri kullanmış ve birleştirilmiş yaklaşımın tahmin doğruluğunu artırabileceğini ve sağlam hava kalitesi izleme çözümleri sağlayabileceğini göstermiştir. Şekil 6, RNN modelin temel yapısını ve bilgi akışını göstermektedir [54].




Şekil-6: RNN Model Mimarisi [54]

### 2.2.6. Çekişmeli Üretken Ağlar

Generative Adversarial Networks (GAN): GAN'ler, veri üretimi ve simülasyonlar için kullanılan çekişmeli üretici ağıdır. Hava kalitesi modellerinde, eksik veya az sayıda veri olduğunda GAN'ler kullanılarak bu veri açığı kapatılabilir.

GAN'ler, iki sinir ağı modelinin (generatör ve diskriminatör) rekabetçi bir şekilde çalışmasıyla, gerçekçi veri üretir. Toutouh vd. [37] tarafından yapılan çalışma, kentsel hava kirliliğini modellemek için Koşullu Üretken Çekişmeli Ağların (CGAN'ler) kullanılmasına odaklanmaktadır. Modelde alınan veriler eğitilmiş ve daha az hesaplama kaynağı gerektiren doğru ve çeşitli kirlilik verileri üretmede umut verici sonuçlar göstermiştir [55], aerosol ve Hava Kalitesi Endeksi değerlerini tahmin etmek için bir nöral Turing makinesini bir GAN ile birleştiren DAerosol.GAN.NTM (Deep Aerosol Generative Adversarial Networks Neural Topic Modeling) çerçevesini önermiştir. Bu model, eksik verileri doğru bir şekilde tahmin ederek ve gelecekteki hava kalitesi ölçümlerini tahmin etmeyi amaçlamaktadır. Wu vd. [56] tarafından yapılan çalışmada ise, şehir planlaması ve hava kalitesi izleme dahil olmak üzere yapıllı çevrede GAN'ların uygulanmasının bir incelemesini sunmaktadır. Bu çalışmanın sonucuna göre, GAN'ların yüksek çözünürlüklü görüntüler oluşturmada ve anlamsal verileri hava kalitesini izlemek ve tahmin etmek için uygulanabilecek gerçekçi görselleştirmelere dönüştürmede etkili olduğunu göstermektedir. Şekil 7 GAN modelinin işleyişini göstermektedir. Bu döngü, Generator'un daha gerçekçi veriler üretmesini ve Ayrıştırıcının bu verileri ayırt etme yeteneğinin sürekli gelişmesini sağlamaktadır [57].



Şekil-7: GAN Model Mimarisi [57]

## 3. Yapay Zekâ Tabanlı Yöntemlerin Karşılaştırılması ve Değerlendirilmesi

Yapay zekâ tabanlı hava kalitesi tahmin yöntemleri üzerine yapılan çalışmalar, bu yöntemlerin etkinliğini ve doğruluğunu karşılaştırmalı olarak analiz etmiştir. RF, SVM, ANN, CNN, RNN ve GAN gibi modeller, hava kalitesi tahmininde kullanılan yöntemler arasında bulunmaktadır.

Kullanılan algoritmalar izlendiğinde ise; mevcut literatürde, RF modelleri yaygın olarak kullanılırken çevresel koşullar ve sensör performansında geleneksel yöntemlere göre yüksek doğruluk sağladığı görülmüştür [32]. SWM modelleri, yüksek boyutlu veri setlerini ve karmaşık ilişkileri işleyebilme yetisine sahiptir. Bu nedenle karmaşık hava kalitesi verilerinde yüksek doğruluk sağladığı görülmüştür [34]. ANN ise hava kalitesi tahmininde sıkça kullanılan en etkili modellerden biridir. Kumar vd. [35] çalışmasında çevresel ve meteorolojik parametreleri kullanarak farklı parametreler arasındaki karmaşık ilişkileri yakalama yeteneğini göstermiştir. CNN'ler kullanılarak yapılan çalışmalarda yüksek doğruluk elde edildiği gözlenmiştir [58]. CNN'ler, Çin'deki hava kalitesi tahmininde kullanılmış ve yüksek doğruluk oranları elde edilmiştir [58]. Benzer şekilde, RNN'ler kullanılarak yapılan bir çalışmada,

Hindistan'daki hava kalitesi tahminleri başarıyla yapılmıştır [29]. Bu çalışmalar, yapay zekânın hava kalitesi tahmininde etkili olduğunu göstermektedir. Farklı yapay zekâ modellerinin karşılaştırmalı analizi de literatürde yer almaktadır. Bir çalışma, CNN ve RNN modellerini karşılaştırarak, CNN'lerin uzamsal verilerde daha iyi performans gösterdiğini, RNN'lerin ise zaman serisi analizlerinde üstün olduğunu belirtmiştir [59]. GAN modelleri ise veri üretimi ve simülasyonlar için kullanılır. GAN modelleri, eksik verilerin doldurulmasında ve gerçekçi veri üretiminde etkili olup, hava kalitesi tahmininde kullanılmaktadır.

Bu modeller, hava kalitesi tahmininde çeşitli avantajlar ve zorluklar sunar (Tablo 2).

Tablo-2: Hava Kalitesi Tahmininde Kullanılan Yapay Zekâ Modelleri

Model	Kullanım Alanları	Avantajlar	Dezavantajlar
RF	Sınıflandırma ve regresyon problemleri	Gürültüye dayanıklılık, büyük veri setleriyle başa çıkma	Parametre ayarlaması ve sonuçların yorumu zor olabilir
SVM	Sınıflandırma ve regresyon	Küçük örneklem setlerinde yüksek performans, gürültüye dayanıklılık	Büyük veri setlerinde yavaş çalışabilir
ANN	Çeşitli veri analizi ve tahmin	Karmaşık doğrusal olmayan ilişkileri modelleme	Optimum ağ yapısını belirlemek zor, aşırı öğrenme riski
CNN	Görüntü ve uzamsal veri analizi	Yüksek doğruluk, mekânsal analiz	Veri yoğunluğu, yüksek hesaplama maliyeti
RNN	Zaman serisi verilerinin analizi	Uzun dönem bağımlılıkları modelleme, zaman serisi analizinde doğruluk	Uzun dönem bağımlılıkları modelleme zorluğu
GAN	Veri üretimi ve simülasyonlar	Eksik verilerin doldurulması, gerçekçi veri üretimi	Generatör ve diskriminatör modellerinin eğitim zorluğu

### 3.1. Gelecek Araştırmalar İçin Öneriler ve Yapay Zekâ Teknolojilerinin Rolü

Gelecek araştırmalarda, yapay zekâ teknolojilerinin hava kalitesi yönetimindeki rolü daha da artacaktır. Yapay zekânın bütünleştirildiği hava kalitesi izleme teknolojileri önemli faydalar sağlarken, bu teknolojilerin tam potansiyellerine ulaşabilmesi için çözülmesi gereken çeşitli zorlukları da beraberinde getirmektedir. Yapay zekâ modellerinin

bütünleştirildiği cihazlar tarafından oluşturulan büyük veri hacimlerini yönetmek, depolamak ve gerçek zamanlı olarak analiz etmek, sağlam bir bulut altyapısı ve gelişmiş veri analizi araçları gerektirir. Bu nedenle veri kalitesi, doğruluğu ve bütünlüğü büyük önem taşır.

Hibrit modellerin geliştirilmesi ile hem mekânsal hem de zamansal bağımlılıkları yakalayarak daha kapsamlı tahminler yapılabilir. RF ve SVM'nin güçlü yönlerinin ve CNN ve RNN gibi derin öğrenme modellerinin güçlü yönlerini birleştirmek farklı yapay zekâ modellerini birleştirmek, yapay zekânın sağlamlığını ve doğruluğunu artırabilir.

Değişen çevre koşullarına sahip farklı coğrafi bölgelere uygulanabilecek ölçeklenebilir ve aktarılabilir yapay zekâ modellerinin geliştirilmesi ile etkinliği artırılabilir. Böylece, bir bölgenin verileri üzerinde eğitilebilecek ve diğerine başarılı bir şekilde uygulanabilecek uyarlanabilir modeller oluşturarak daha geniş alanlarda uygulanabilir.

Verilerin kalitesinin ve kullanılabilirliğinin sağlanması bu modellerin doğru açılarından önemlidir. Bu alandaki sürekli iyileştirmeler, yapay zekâ tabanlı cihazların doğruluğu, güvenilirliği ve maliyet etkinliğini artırmasını sağlayacaktır. Yapay zekâ ve makine öğrenimi gibi teknolojilerin hızla gelişmesi ve yapay zekânın entegrasyonu, veri analizi ve tahmin yeteneklerini önemli ölçüde artırabilir.

Yapay zekâ teknolojileri, yapay zekâ tabanlı sensörlerin ve gelişmiş veri işleme tekniklerinin entegrasyonu yoluyla hava kalitesinin gerçek zamanlı izlenmesine olanak tanımaktadır. Bu durum, kirlilikteki ani artışların zamanında tespit edilmesine ve politika yapıcıların kirlilik kaynaklarını azaltmak için stratejiler geliştirmesine olanak tanıyarak hava kalitesinin halk sağlığı üzerindeki olumsuz etkilerini azaltabilir.

## 4. Sonuç

Bu çalışma, yapay zekâ tabanlı hava kalitesi tahmin ve iyileştirme stratejilerini kapsamlı bir şekilde incelemektedir. RF, SVM, ANN, CNN, RNN ve GAN gibi modern yapay zekâ modellerinin hava kalitesi tahmininde nasıl kullanıldığı ve bu modellerin avantajları ile dezavantajları ele alınmıştır. Literatürdeki bulgular, bu modellerin hava kalitesi tahmininde yüksek doğruluk sağladığını ve çeşitli çevresel koşullarda da etkili olduğunu göstermektedir.

Gelecek araştırmalarda, yapay zekâ teknolojilerinin hava kalitesi yönetiminde daha geniş bir rol oynayacağı öngörülmektedir. Gelişmiş algoritmalar ve daha büyük veri kümeleri, daha hassas tahminler ve etkili iyileştirme stratejileri geliştirilmesine olanak tanıyacaktır. Ayrıca, yapay zekâ tabanlı modellerin gerçek zamanlı izleme sistemlerine entegrasyonu, proaktif hava kalitesi yönetimi için kritik bir adım olacaktır.

Sonuç olarak, yapay zekâ teknolojilerinin hava kalitesi tahmini ve yönetiminde büyük bir potansiyele sahip olduğu açıkça görülmektedir. Bu teknolojiler, hava kirliliği ile mücadelede etkili stratejiler geliştirilmesine yardımcı olabilir ve çevresel sürdürülebilirliği destekleyebilir. Gelecek araştırmalarda, yapay zekâ ve hava kalitesi ilişkisinin daha derinlemesine incelenmesi ve bu alandaki yeniliklerin yakından takip edilmesi önemlidir.

## 5. Kaynaklar

- [1] S. Sharma, M. Zhang, Anshika, J. Gao, H. Zhang, S.H. Kota, "Effect of Restricted Emissions During COVID-19 on Air Quality in India," *The Science of the Total Environment*, 2020
- [2] K. Balakrishnan, S. Dey, T. Gupta, R.S. Dhaliwal, M. Brauer, A.J. Cohen, J.D. Stanaway, G. Beig, T.K. Joshi, A.N. Aggarwal, Y. Sabde, H. Sadhu, J. Frostad, K. Causey, W. Godwin, D.K. Shukla, G.A. Kumar, C.M. Varghese, P. Muraleedharan, A. Agrawal, R.M. Anjana, A. Bhansali, D. Bhardwaj, K. Burkart, K. Cercy, J.K. Chakma, S. Chowdhury, D.J. Christopher, E. Dutta, M. Furtado, S. Ghosh, A.G. Ghoshal, S.D. Glenn, R. Guleria, R. Gupta, P. Jeemon, R. Kant, S. Kant, T. Kaur, P.A. Koul, V. Krish, B. Krishna, S.L. Larson, K. Madhipatla, P.A. Mahesh, V. Mohan, S. Mukhopadhyay, P. Mutreja, N. Naik, S. Nair, G. Nguyen, C.M. Odell, J.D. Pandian, D. Prabhakaran, P. Prabhakaran, A. Roy, S. Salvi, S. Sambandam, D. Saraf, M. Sharma, A. Shrivastava, V. Singh, N. Tandon, N.J. Thomas, A. Torre, D. Xavier, G. Yadav, S. Singh, C. Shekhar, T. Vos, R. Dandona, K.S. Reddy, S.S. Lim, C.J.L. Murray, S. Venkatesh, L. Dandona, "The impact of air pollution on deaths, disease burden, and life expectancy across the states of India: the Global Burden of Disease Study 2017," *The Lancet Planetary Health*, vol. 3, no. 1, 2019
- [3] C.A. Pope, D.W. Dockery, "Health effects of fine particulate air pollution: Lines that connect," *Journal of the Air and Waste Management Association*, vol. 56, no. 6, 2006
- [4] WHO, "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." [Online]. Available: <https://apps.who.int/iris/handle/10665/345329>
- [5] M.A. Zoran, R.S. Savastru, D.M. Savastru, M.N. Tautan, "Assessing the relationship between surface levels of PM<sub>2.5</sub> and PM<sub>10</sub> particulate matter impact on COVID-19 in Milan, Italy," *Science of the Total Environment*, vol. 738, 2020
- [6] J.O. Anderson, J.G. Thundiyil, A. Stolbach, "Clearing the Air: A Review of the Effects of Particulate Matter Air Pollution on Human Health," *Journal of Medical Toxicology*, vol. 8, no. 2, 2012.
- [7] A. Ratajczak, A. Badyda, P.O. Czechowski, A. Czarnecki, M. Dubrawski, W. Feleszko, "Air pollution increases the incidence of upper respiratory tract symptoms among Polish children," *Journal of Clinical Medicine*, vol. 10, no. 10, p. 2150, 2021.
- [8] T. Bourdrel, M.A. Bind, Y. Béjot, O. Morel, J.F. Argacha, "Cardiovascular effects of air pollution," *Archives of Cardiovascular Diseases*, vol. 110, no. 11, 2017.
- [9] R.B. Hamanaka, G.M. Mutlu, "Particulate matter air pollution: effects on the cardiovascular system," *Frontiers in endocrinology*, vol. 9, p. 680, 2018.
- [10] M. Laeremans, E. Dons, I. Avila-Palencia, G. Carrasco-Turigas, J.P. Orjuela, E. Anaya, T. Cole-Hunter, A. De Nazelle, M. Nieuwenhuijsen, A. Standaert, "Short-term effects of physical activity, air pollution and their interaction on the cardiovascular and respiratory system," *Environment international*, vol. 117, pp. 82–90, 2018.
- [11] C. Spix, H.R. Anderson, J. Schwartz, M.A. Vigotti, A. Letertre, J.M. Vonk, G. Touloumi, F. Balducci, T. Piekarski, L. Bacharova, "Short-term effects of air pollution on hospital admissions of respiratory diseases in Europe: a quantitative summary of APHEA study results," *Archives of Environmental Health: An International Journal*, vol. 53, no. 1, pp. 54–64, 1998.
- [12] M. Kampa, E. Castanas, "Human health effects of air pollution," *Environmental pollution*, vol. 151, no. 2, pp. 362–367, 2008.
- [13] L. Schinasi, R.A. Horton, V.T. Guidry, S. Wing, S.W. Marshall, K.B. Morland, "Air pollution, lung function, and physical symptoms in communities near concentrated swine feeding operations," *Epidemiology*, vol. 22, no. 2, 2011
- [14] A.J. Elliot, S. Smith, A. Dobney, J. Thornes, G.E. Smith, S. Vardoulakis, "Monitoring the effect of air pollution episodes on health care consultations and ambulance call-outs in England during March/April 2014: A retrospective observational analysis," *Environmental pollution*, vol. 214, pp. 903–911, 2016.
- [15] Y. Xue, L. Wang, Y. Zhang, Y. Zhao, Y. Liu, "Air pollution: A culprit of lung cancer," *Journal of Hazardous Materials*, vol. 434, 2022.
- [16] T. Pekdogan, M.T. Udriștioiu, H. Yildizhan, A. Ameen, "From Local Issues to Global Impacts: Evidence of Air Pollution for Romania and Turkey," *Sensors*, vol. 24, no. 4, p. 1320, 2024.
- [17] G. Başdoğan, Ç. Arzu, "Ecological-social-economical impacts of vertical gardens in the sustainable city model," *Yuzuncu Yıl University Journal of Agricultural Sciences*, vol. 26, no. 3, pp. 430–438, 2016.
- [18] X. Lu, S. Zhang, J. Xing, Y. Wang, W. Chen, D. Ding, Y. Wu, S. Wang, L. Duan, J. Hao, "Progress of Air Pollution Control in China and Its Challenges and Opportunities in the Ecological Civilization Era," *Engineering*, vol. 6, no. 12, 2020.



- [19] M. Angelidou, A. Psaltoglou, N. Komninos, C. Kakderi, P. Tsarchopoulos, A. Panori, “Enhancing sustainable urban development through smart city applications,” *Journal of Science and Technology Policy Management*, 2018
- [20] L. García, A.J. Garcia-Sanchez, R. Asorey-Cacheda, J. Garcia-Haro, C.L. Zúñiga-Cañón, “Smart Air Quality Monitoring IoT-Based Infrastructure for Industrial Environments,” *Sensors*, vol. 22, no. 23, 2022
- [21] Y. Yang, “IoT-based air pollution monitoring system,” *Highlights in Science, Engineering and Technology*, vol. 17, pp. 299–307, Nov.2022
- [22] Ö. Zeydan, M. Pekkaya, “Evaluating air quality monitoring stations in Turkey by using multi criteria decision making,” *Atmospheric Pollution Research*, vol. 12, no. 5, p. 101046, 2021.
- [23] A. Suleiman, M.R. Tight, A.D. Quinn, “Applying machine learning methods in managing urban concentrations of traffic-related particulate matter (PM10 and PM2.5),” *Atmospheric Pollution Research*, vol. 10, no. 1, 2019
- [24] M. Taştan, “A low-cost air quality monitoring system based on Internet of Things for smart homes,” *Journal of Ambient Intelligence and Smart Environments*, vol. 14, no. 5, 2022
- [25] A. Gacar, H. Aktas, B. Ozdogan, “Digital agriculture practices in the context of agriculture 4.0,” *Pressacademia*, vol. 4, no. 2, 2017
- [26] M.S. Farooq, S. Riaz, A. Abid, T. Umer, Y. Bin Zikria, “Role of iot technology in agriculture: A systematic literature review,” *Electronics (Switzerland)*, vol. 9, no. 2. 2020.
- [27] B. Bahmei, E. Birmingham, S. Arzanpour, “CNN-RNN and Data Augmentation Using Deep Convolutional Generative Adversarial Network for Environmental Sound Classification,” *IEEE Signal Processing Letters*, vol. 29, 2022
- [28] X. Li, L. Peng, X. Yao, S. Cui, Y. Hu, C. You, T. Chi, “Long short-term memory neural network for air pollutant concentration predictions: Method development and evaluation,” *Environmental Pollution*, vol. 231, 2017
- [29] P.W. Tien, S. Wei, J. Darkwa, C. Wood, J.K. Calautit, “Machine Learning and Deep Learning Methods for Enhancing Building Energy Efficiency and Indoor Environmental Quality – A Review,” *Energy and AI*, vol. 10. 2022.
- [30] S.C. Sofuoglu, A. Sofuoglu, S. Birgili, G. Tayfur, “Forecasting ambient air SO2 concentrations using artificial neural networks,” *Energy Sources, Part B: Economics, Planning and Policy*, vol. 1, no. 2, 2006
- [31] R.S. Suri, A.K. Jain, N.R. Kapoor, A. Kumar, H.C. Arora, K. Kumar, H. Jahangir, “Air Quality Prediction-A Study Using Neural Network Based Approach,” *Journal of Soft Computing in Civil Engineering*, vol. 7, no. 1, pp. 93–113, Jan.2023
- [32] A.R. Alsaber, J. Pan, A. Al-Hurban, “Handling complex missing data using random forest approach for an air quality monitoring dataset: A case study of kuwait environmental data (2012 to 2018),” *International Journal of Environmental Research and Public Health*, vol. 18, no. 3, pp. 1–26, Feb.2021
- [33] C.C. Liu, T.C. Lin, K.Y. Yuan, P. Te Chiueh, “Spatio-temporal prediction and factor identification of urban air quality using support vector machine,” *Urban Climate*, vol. 41, Jan.2022
- [34] M.A. Rafif, G. Sanjaya Indrajaya, M.K. Al-Ghazi, J. Johnny, N.T.M. Sagala, “Comparison of Decision Tree and Support Vector Machine for Predicting Jakarta Air Quality Index,” in *ICCoSITE 2023 - International Conference on Computer Science, Information Technology and Engineering: Digital Transformation Strategy in Facing the VUCA and TUNA Era*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 381–385.
- [35] K. Kumar, B.P. Pande, “Air pollution prediction with machine learning: a case study of Indian cities,” *International Journal of Environmental Science and Technology*, vol. 20, no. 5, pp. 5333–5348, May2023
- [36] W.-T. Tsai, Y.-Q. Lin, “Trend Analysis of Air Quality Index (AQI) and Greenhouse Gas (GHG) Emissions in Taiwan and Their Regulatory Countermeasures,” *Environments*, 2021
- [37] J. Toutouh, S. Nesmachnow, D.G. Rossit, “Generative adversarial networks to model air pollution under uncertainty,” in *CEUR Workshop Proceedings*, 2021.
- [38] V. Athira, P. Geetha, R. Vinayakumar, K.P. Soman, “DeepAirNet: Applying Recurrent Networks for Air Quality Prediction,” in *Procedia Computer Science*, Elsevier B.V., 2018, pp. 1394–1403.
- [39] N. Zimmerman, A.A. Presto, S.P.N. Kumar, J. Gu, A. Hauryliuk, E.S. Robinson, A.L. Robinson, R. Subramanian, “A machine learning calibration model using random forests to improve sensor performance for lower-cost air quality monitoring,” *Atmospheric Measurement Techniques*, vol. 11, no. 1, pp. 291–313, 2018
- [40] R. Yu, Y. Yang, L. Yang, G. Han, O.A. Move, “RAQ–A random forest approach for predicting air quality in urban sensing systems,” *Sensors (Switzerland)*, vol. 16, no. 1, Jan.2016

- [41] K. Zhang, J. Yang, J. Sha, H. Liu, "Dynamic slow feature analysis and random forest for subway indoor air quality modeling," *Building and Environment*, vol. 213, 2022
- [42] A. Moradibaad, R. Mashhoud, "Use Dimensionality Reduction and SVM Methods to Increase the Penetration Rate of Computer Networks." 2018.
- [43] M. Gao, L. Yin, J. Ning, "Artificial neural network model for ozone concentration estimation and Monte Carlo analysis," *Atmospheric Environment*, vol. 184, 2018
- [44] J. Ordieres-Meré, E. Vergara, S. Capuz-Rizo, R. Salazar, "Neural network prediction model for fine particulate matter (PM2.5) on the US–Mexico border in El Paso (Texas) and Ciudad Juárez (Chihuahua)," *Environmental Modelling & Software*, vol. 20, pp. 547–559, May 2005
- [45] M.J. Moradi, M.A. Hariri-Ardebili, "Developing a library of shear walls database and the neural network based predictive meta-model," *Applied Sciences*, vol. 9, no. 12, p. 2562, 2019.
- [46] Z. Bai, C. Peng, "Convolutional Neural Network (CNN) Supported Urban Design to Reduce Particle Air Pollutant Concentrations," in *Proceedings of the 28th Conference on Computer Aided Architectural Design Research in Asia (CAADRIA) [Volume 1]*, 2023.
- [47] Y. Mao, S. Lee, "Deep Convolutional Neural Network for Air Quality Prediction," in *Journal of Physics: Conference Series*, 2019.
- [48] E. Akin, M.E. Şahin, "Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme," *EMO Bilimsel Dergi*, vol. 14, no. 1, pp. 27–38, 2024 [Online]. Available: <https://dergipark.org.tr/tr/pub/emobd/issue/83029/1338066>
- [49] S. Ramachandraarjunan, V. Perumalsamy, B. Narayanan, "IoT based artificial intelligence indoor air quality monitoring system using enabled RNN algorithm techniques," *Journal of Intelligent and Fuzzy Systems*, vol. 43, no. 3, 2022
- [50] H. Nurcahyanto, A.T. Prihatno, M.M. Alam, M.H. Rahman, I. Jahan, M. Shahjalal, Y.M. Jang, "Multilevel RNN-Based PM10 Air Quality Prediction for Industrial Internet of Things Applications in Cleanroom Environment," *Wireless Communications and Mobile Computing*, vol. 2022, 2022
- [51] X. Zhao, R. Zhang, J.L. Wu, P.C. Chang, "A deep recurrent neural network for air quality classification," *Journal of Information Hiding and Multimedia Signal Processing*, vol. 9, no. 2, pp. 346–354, Mar. 2018.
- [52] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, W. Woo, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting," *Advances in neural information processing systems*, vol. 28, 2015.
- [53] S.J. Livingston, S.D. Kanmani, A.S. Ebenezer, D. Sam, A. Joshi, "An ensemble method for air quality monitoring and control using machine learning," *Measurement: Sensors*, vol. 30, 2023
- [54] K. Gaurav, B.K. Singh, V. Kumar, "Intelligent fault monitoring and reliability analysis in safety-critical systems of nuclear power plants using SIAO-CNN-ORNN," *Multimedia Tools and Applications*, 2024
- [55] Z.S. Asaci-Moamam, F. Safi-Esfahani, S. Mirjalili, R. Mohammadpour, M.H. Nadimi-Shahraki, "Air quality particulate-pollution prediction applying GAN network and the Neural Turing Machine," *Applied Soft Computing*, vol. 147, 2023
- [56] A.N. Wu, R. Stouffs, F. Biljecki, "Generative Adversarial Networks in the built environment: A comprehensive review of the application of GANs across data types and scales," *Building and Environment*, vol. 223. 2022.
- [57] S. Sarwar, G. Aziz, D. Balsalobre-Lorente, "Forecasting Accuracy of Traditional Regression, Machine Learning, and Deep Learning: A Study of Environmental Emissions in Saudi Arabia," *Sustainability*, vol. 15, no. 20, 2023
- [58] W. Huang, T. Li, J. Liu, P. Xie, S. Du, F. Teng, "An overview of air quality analysis by big data techniques: Monitoring, forecasting, and traceability," *Information Fusion*, vol. 75. 2021.
- [59] M. Méndez, M.G. Merayo, M. Núñez, "Machine learning algorithms to forecast air quality: a survey," *Artificial Intelligence Review*, vol. 56, no. 9, 2023

## Özgeçmiş



Dr. Öğr. Üyesi Tuğçe Pekdoğan, İzmir Yüksek Teknoloji Enstitüsü'nden mimarlık alanında doktora derecesine sahiptir ve aynı üniversitede yüksek lisans yapmıştır. Lisans eğitimini Doğu Akdeniz Üniversitesi'nde fakülte birincisi olarak tamamlamıştır.

Şu anda Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesinde çalışmakta olan Dr. Pekdoğan'ın araştırma alanları arasında bina enerji performansı, ısı transferi, bina enerji modellemesi ve simülasyonu, termal konfor, iç mekan hava kalitesi ve iç çevre kalitesi gibi konular bulunmaktadır. Bu konular üzerine birçok uluslararası ve ulusal makale yayınlamıştır. Science Citation Index (SCI) ve SCI Expanded (SCI-E) indekslerinde yer alan dergilerde 10'dan fazla makalesi yayımlanmış olup, SCOPUS ve diğer mimarlık indekslerinde de çeşitli makaleleri bulunmaktadır.

Ayrıca, TÜBİTAK ve Erasmus+ tarafından desteklenen projelerde de yer almıştır. Öne çıkan projeleri arasında TÜBİTAK 1002 projesi olan "İç Mekan Çevre Kalitesine Çok Yönlü Bir Yaklaşım: Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi Mimarlık Tasarım Stüdyosu Örneği" ve Erasmus+ projesi olan "Hava Kirliliği ile İlgili Bazı İleri Teknolojilerin Öğretim ve Araştırmada Uygulanması" bulunmaktadır. Bina cepheleri için faz değiştiren malzeme ile entegre edilen ısı geri kazanım ünitesinin deneysel ve sayısal araştırması üzerine doktora tezini tamamlamış olup ulusal patenti bulunmaktadır.