

Ozon Konsantrasyonunun Marmara Bölgesi İstasyonlarındaki Hava Kirliliği ve Meteorolojik Ölçümler Kullanılarak Makine Öğrenmesi Modelleriyle Tahmini

Prediction of Ozone Concentration Using Machine Learning Models Based on Air Pollutants and Meteorological Variables in the Marmara Region

Prof. Dr. Pınar ERGENEKON

Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Bölümü, Kocaeli, Türkiye
p.kus@gtu.edu.tr
ORCID: 0000-0002-0555-5932

Arş. Gör. Gizem ÇELİK

Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Bölümü, Kocaeli, Türkiye
g.yaran@gtu.edu.tr
ORCID: 0000-0003-4069-0846

Şeymanur SÜLÜN

Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Bölümü, Kocaeli, Türkiye
seymanur-00@hotmail.com

Serhat KEÇECİ

Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Bölümü, Kocaeli, Türkiye
serhat.kececi@hotmail.com

Makale Türü:

İNCELEME

Gönderilme Tarihi:

30 Nisan 2025

Kabul Tarihi:

16 Mayıs 2025

Öz

Ozon (O_3), çevresel ve sağlık açısından kritik öneme sahip bir kirleticidir, bazı hava kalitesi izleme istasyonlarında ölçümü yapılmamakta ya da ölçüm verileri eksik olabilmektedir. Bu çalışmada, Marmara Bölgesi'ndeki seçili hava kalitesi izleme istasyonlarındaki ozon konsantrasyonlarının makine öğrenmesi yöntemleriyle tahmin edilmesi amaçlanmıştır. Bu doğrultuda, Marmara Bölgesinde İstanbul, Sakarya ve Edirne illerinde bulunan seçili üç istasyon için beş yıllık diğer hava kalitesi parametreleri ve meteorolojik veriler elde edilerek, kullanıma hazır hale getirilmiştir. Ardından, ozon konsantrasyonları farklı makine öğrenmesi tabanlı regresyon modelleri kullanılarak tahmin edilmiş ve model performansları karşılaştırılmıştır. En başarılı sonuçlar Random Forest ($R^2=0.70-0.78$) ve DART ($R^2=0.69-0.77$) algoritmaları ile elde edilmiştir. Modellerin değerlendirilmesinde sıcaklık, nem gibi meteorolojik verilerin yanı sıra, azot oksit bileşiklerinin (NO , NO_2 , NOX) en önemli model değişkenleri olduğu görülmüştür. Çalışma, ozon ölçümü yapılmayan veya eksik veri içeren bölgelerde, makine öğrenmesi yöntemleri ile güvenilir tahmin yapılabileceğini göstermektedir. Trafik verilerinin de modele entegre edilmesiyle daha iyi tahmin etme modelleri oluşturularak, hava kalitesi yönetiminde maliyetleri azaltma ve karar destek sistemi olarak kullanılabilecek önemli bir potansiyel sunması öngörülmektedir.

Anahtar Kelimeler: Ozon Tahmini, Hava Kalitesi, Makine Öğrenmesi, Regresyon Modeli, Marmara Bölgesi.

Abstract

Ozone (O_3) is a pollutant of critical importance for both environmental and health concerns; however, it is not measured at some air quality monitoring stations, or measurement data may be incomplete. In this study, the aim is to predict ozone concentrations at selected air quality monitoring stations in the Marmara Region using machine learning methods. For this purpose, five years of other air quality parameters and meteorological data were collected and prepared for use for three selected stations located in Istanbul, Sakarya, and Edirne provinces within the Marmara Region. Subsequently, ozone concentrations were predicted using different machine learning-based regression models, and the model performances were compared. The best results were obtained with the Random Forest ($R^2 = 0.70-0.78$) and DART ($R^2 = 0.69-0.77$) algorithms. It was observed that, in addition to meteorological variables such as temperature and humidity, nitrogen oxide compounds (NO , NO_2 or NOX) were the most important variables in the models. This study demonstrates that reliable predictions can be made in areas where ozone measurements are unavailable or incomplete by using machine learning methods. It is anticipated that integrating traffic data into the models could lead to the development of even more accurate prediction models, offering significant potential for reducing costs in air quality management and serving as a decision support system.

Keywords: Ozone Prediction, Air Quality, Machine Learning, Regression Model, Marmara Region.

1.Giriş

Hava kalitesi, toplum sağlığı ve çevresel sürdürülebilirlik açısından kritik bir öneme sahiptir. Yer seviyesi ozon (O_3), troposferde fotokimyasal reaksiyonlar sonucu oluşan ve hem insan sağlığı hem de ekosistemler üzerinde önemli olumsuz etkilere yol açan bir ikincil kirleticidir. Azot oksitler (NOX) ve uçucu organik bileşiklerin (VOC) güneş ışığı altında gerçekleştirdiği reaksiyonlarla oluşan ozon, solunum yolu hastalıklarından tarımsal verim kayıplarına, iklim değişikliği etkilerinden malzeme aşınmasına kadar geniş bir yelpazede zararlı sonuçlar doğurabilmektedir (Jiménez-Navarro, Martínez-Ballesteros, Martínez-Álvarez, & Asencio-Cortés, 2024). Özellikle şehir merkezlerinde, trafik kaynaklı emisyonların yoğunluğu ve artan güneşlenme süresi, ozon oluşum süreçlerini daha da hızlandırmaktadır (Cao, Zhao, Su, Cheng, & Ren, 2023; Jiménez-Navarro vd., 2024). Günümüzde şehirleşmenin ve sanayileşmenin hızla artması, özellikle yoğun trafik, enerji üretimi ve sanayi faaliyetleri sonucu atmosfere salınan öncül gazların artmasına sebep olmuş; bu da yer seviyesi ozon problemini daha karmaşık ve yönetilmesi güç bir hale getirmiştir (Cao vd., 2023). Meteorolojik faktörler, özellikle sıcaklık, güneşlenme süresi, rüzgar hızı ve bağıl nem, ozon oluşumu üzerinde doğrudan belirleyici rol oynamaktadır. Yüksek sıcaklıklar ve durağan hava koşulları, ozon birikimini artıran başlıca faktörler arasında yer almaktadır (Du, Qiao, Lu, & Yu, 2022). Nitekim yapılan çalışmalar, düşük rüzgar hızları ve yüksek güneş radyasyonu varlığında ozon seviyelerinin kritik eşikleri aşabildiğini göstermektedir (Cao vd., 2023).

Ozon konsantrasyonlarının tahmin edilmesi, erken uyarı sistemleri kurulması, halk sağlığının korunması ve etkili hava kalitesi yönetim politikalarının geliştirilmesi açısından büyük önem arz etmektedir. Ancak, ozon oluşum süreçleri oldukça karmaşık olup, öncül gazların konsantrasyonları ile meteorolojik değişkenler arasındaki ilişkiler doğrusal olmayan, dinamik ve çok değişkenli yapıdadır (Cheng vd., 2023). Bu karmaşık yapıyı doğru şekilde modelleyebilmek, geleneksel istatistiksel yöntemlerle sınırlı kalmaktadır. Özellikle doğrusal regresyon temelli modeller, ozon oluşumunun ardındaki karmaşık neden-sonuç ilişkilerini tam olarak açıklamada yetersiz kalmaktadır (Du vd., 2022; Wu, He, Song, & Peng, 2022). Bu nedenle son yıllarda makine öğrenmesi (ML) teknikleri, hava kalitesi tahmin çalışmalarında güçlü bir alternatif olarak öne çıkmıştır. Makine öğrenmesi algoritmaları, büyük ve çok boyutlu veri setleri üzerinde karmaşık, doğrusal olmayan ilişkileri öğrenebilme ve yüksek doğrulukta tahminler üretebilme yetenekleri sayesinde hava kirleticilerin dinamiklerini modellemek için sıklıkla tercih edilmektedir (Hosseinpour, Kumar, Tran, & Knipping, 2024). Özellikle Random Forest, Gradient Boosting, XGBoost gibi ağaç tabanlı regresyon algoritmaları, hem modelleme doğruluğu hem de değişken etkilerinin yorumlanabilirliği açısından başarılı sonuçlar vermektedir (Cheng vd., 2023; Du vd., 2022). Bu algoritmalar, farklı meteorolojik ve hava kirliliği verilerinin birlikte işlendiği çalışmalarda, klasik yöntemlere kıyasla belirgin doğruluk avantajı sunmaktadır (Cheng vd., 2023; Lyu vd., 2022).

Son dönemde yapılan çalışmalar, yalnızca ozon konsantrasyonlarının kısa vadeli tahminini değil, aynı zamanda hangi meteorolojik ve kirletici değişkenlerin ozon oluşumuna en çok katkı sağladığının da belirlenebildiğini göstermektedir. Örneğin, Cheng vd. (2023), PMF-SHAP yöntemini kullanarak farklı VOC kaynaklarının ozon üretimi üzerindeki etkilerini makine öğrenmesi ile ayrıntılı biçimde modellemişlerdir (Cheng vd., 2023). Benzer şekilde, Jiménez-Navarro vd. (2024) zaman serisi verilerinde öznetelik seçimi yaparak, derin öğrenme tabanlı modellerin hem performansını hem de yorumlanabilirliğini artırmışlardır (Jiménez-Navarro vd., 2024). Hong vd. (2023), saatlik ozon tahmininde periyodik davranışları tanımlamak için çok dereceli farklılık içeren MDE-LSTM modelini geliştirerek, kısa dönemli ozon dalgalanmalarının daha iyi öngörülebileceğini göstermiştir (Hong, Ji, Rao, Chen, & Sun, 2023). Du vd. (2022), Houston bölgesinde gerçekleştirdikleri çalışmada, trafik verileri ve meteorolojik değişkenler kullanarak makine öğrenmesi algoritmalarıyla yıllık ölçekli saatlik ozon tahmini yapmış ve XGBoost algoritmasının en yüksek doğruluğu sağladığını rapor etmiştir (Du vd., 2022). Ahmad vd. (2022), Meksika Şehri'nde meteorolojik değişkenleri kullanarak makine öğrenmesi modelleriyle başarılı ozon tahminleri gerçekleştirmiş ve özellikle sıcaklık, nem ve rüzgar hızının tahmin başarısında belirleyici rol oynadığını ortaya koymuştur (Ahmad, Rappenglück, Osibanjo, & Retama, 2022). Cheng vd. (2023) ise PMF-SHAP metodunu geliştirerek, VOC emisyon

kaynaklarının ozon oluşumu üzerindeki etkilerini hem açıklayıcı hem de nicel şekilde analiz etmiş, makine öğrenmesi algoritmalarını geleneksel faktör analiz yöntemleriyle entegre ederek önemli bir metodolojik yenilik sunmuşlardır (Cheng vd., 2023). Lyu vd. (2022) tarafından yürütülen bir başka çalışmada, Çin'in Beijing-Tianjin-Hebei bölgesinde Random Forest ve Karar Ağacı modelleri kullanılarak ozonun mekânsal ve zamansal dağılımı başarıyla tahmin edilmiştir. Çalışmada sıcaklık ve güneş radyasyonu gibi meteorolojik değişkenlerin ozon oluşumu üzerindeki etkisi net bir şekilde ortaya konmuştur (Lyu vd., 2022). Benzer şekilde Kuo ve Fu (2023), makine öğrenmesi ile model-measurement fusion (MMF) yaklaşımlarını entegre ederek, emisyonların ozon üzerindeki etkilerini daha doğru modellemiş ve geleneksel CMAQ modellerine kıyasla üstün performans elde etmişlerdir (Kuo & Fu, 2023). Mu vd. (2023), Çin'in Jiangsu Eyaleti için R-ConvLSTM tabanlı bir model geliştirerek, zaman serisi verilerinde uzamsal ve zamansal değişkenliklerin daha doğru tahmin edilebileceğini göstermiştir (Mu, Wang, Jiang, & Wu, 2023). Ozon tahmininde sadece tahmin doğruluğu değil, model açıklanabilirliği de önemli bir araştırma konusu olmuştur. Jiménez-Navarro vd. (2024), Zaman Seçim Katmanı (Time Selection Layer) entegre edilmiş derin öğrenme modelleri kullanarak hem model performansını artırmış hem de tahmin edilen ozon seviyelerine en fazla katkı sağlayan değişkenleri daha şeffaf bir şekilde belirlemişlerdir. Bu yaklaşımlar, hava kalitesi tahmininde sadece “ne” olduğunu değil, aynı zamanda “neden” olduğunu açıklamak açısından da kritik önem taşımaktadır (Jiménez-Navarro vd., 2024). Öte yandan, meteorolojik koşulların ozon oluşumu üzerindeki etkisi de birçok çalışmada vurgulanmıştır. Cao vd. (2023), Çin'in Sichuan bölgesinde meteorolojik parametreleri kullanarak ozon kirliliği seviyelerini sınıflandıran bir BP sinir ağı modeli geliştirmiş ve sıcaklık, nem, sınır tabaka yüksekliği gibi değişkenlerin ozon seviyeleri üzerindeki etkisini başarıyla analiz etmiştir (Cao vd., 2023). Yafouz vd. (2021), farklı derin öğrenme ve makine öğrenmesi algoritmalarını ozon tahmininde karşılaştırmış ve hibrit CNN-LSTM modellerinin standalone modellere göre daha yüksek başarı sağladığını raporlamıştır (Yafouz vd., 2021). Ayus vd. (2023), Çin'deki büyük şehirlerde hava kalitesi tahmini için makine öğrenmesi algoritmalarını derin öğrenme modelleriyle karşılaştırmış ve XGBoost'un birçok derin öğrenme mimarisinden daha yüksek performans gösterdiğini bulmuştur (Ayus, Natarajan, & Gupta, 2023).

Tüm bu çalışmalar, makine öğrenmesi yöntemlerinin ozon konsantrasyonu tahmininde geleneksel modellere göre daha yüksek doğruluk, esneklik ve yorumlanabilirlik sağladığını göstermektedir. Ancak özellikle bölgesel ölçekli, çok değişkenli veri setleri kullanılarak yapılan ve eksik ölçüm verilerinin bulunduğu alanlarda uygulanan modeller hâlâ sınırlıdır.

Marmara Bölgesi, yoğun sanayileşme, yüksek trafik yoğunluğu ve artan nüfus gibi faktörlerin etkisiyle ciddi hava kalitesi sorunları yaşayan bir bölgedir. Bölgede yer seviyesi ozon konsantrasyonlarının izlenmesi ve tahmin edilmesi, hem kamu sağlığı önlemleri hem de bölgesel çevre yönetimi açısından kritik öneme sahiptir. Ancak bazı izleme istasyonlarında ozon ölçümleri ya hiç yapılmamakta ya da eksik ve düzensiz veri sorunları yaşanmaktadır. Bu nedenle, makine öğrenmesi tabanlı tahmin modelleri, ölçüm altyapısının yetersiz olduğu alanlarda önemli bir çözüm sunmaktadır.

Bu çalışma, Marmara Bölgesi'ndeki seçili hava kalitesi izleme istasyonlarından elde edilen ozon konsantrasyonu ve meteorolojik değişkenleri kullanarak makine öğrenmesi modelleri ile tahmin modeli geliştirmeyi amaçlamaktadır. Çalışmada ayrıca PM₁₀, PM_{2.5}, NO, NO₂, SO₂ ve CO gibi diğer hava kirleticiler de modele entegre edilmiştir. Kullanılan modeller arasında Random Forest, Gradient Boosting ve DART gibi yöntemler yer almakta olup, performans değerlendirmeleri regresyon doğruluk metrikleri (R², RMSE, MAE) ile yapılmıştır. Çalışmanın özgün yönü, çok değişkenli veri yapısıyla yüksek doğrulukta tahminler gerçekleştirilmesi ve eksik ölçüm altyapısına sahip alanlarda kullanılabilir modellere katkı sağlanmasıdır.

2. Materyal ve Yöntem

2.1. Çalışma Alanı ve Veri Kaynakları

Proje kapsamında, İstanbul-Başakşehir, Edirne-Karaağaç ve Sakarya-Ozanlar olmak üzere 3 hava kalitesi izleme istasyonu seçilmiştir. Bu istasyonlara ait 5 yıllık veriler, Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'na bağlı

Ulusal Hava Kalitesi İzleme Ağı (UHKİA) üzerinden temin edilmiştir.

Meteorolojik veriler (sıcaklık, rüzgar yönü, rüzgar hızı, nem ve yağış) Meteoroloji Genel Müdürlüğü'nden elde edilmiştir. Seçilen 3 hava kalitesi izleme istasyonuna en yakın meteoroloji istasyonları, bu istasyonların kodları ve harita üzerindeki konumları Şekil 1 ve Tablo 1'de gösterilmiştir.

Tablo 1: Hava Kalitesi İzleme İstasyonları ve Meteoroloji İstasyonları.

Hava kalitesi izleme istasyonu	Meteoroloji istasyonu
İstanbul- Başakşehir	İstanbul- Eyüpsultan (18101)
Edirne- Karaağaç	Edirne (17050)
Sakarya- Ozanlar	Sakarya (17069)



Şekil 1. Meteoroloji ve Hava Kalitesi İzleme İstasyonları Arasındaki Mesafe ve Bunların Harita Üzerindeki Gösterimi.

2.2. Veri Hazırlama ve Ön İşleme

Ham veriler, açık kaynaklı R programlama dili ile analiz edilmiştir. Bu amaçla readxl, openair, lubridate, foqat, padr ve writexl gibi paketlerden yararlanılmıştır.

Veri ön işleme sürecinde izlenen adımlar şu şekildedir:

- Negatif değerler, sıfırlar ve ± 3 standart sapmanın dışında kalan anomaliler filtrelenmiştir.
- Hava kalitesi verilerinde saat veya günlük zaman atlamalarının olduğu görüldüğünden, eksik zamanlar yılın tüm günleri ve saatlerini kapsayacak şekilde düzenlenmiştir.
- Ölçülen parametrelerdeki ardışık olmayan eksik değerler, önceki ve sonraki saatlerin ortalamaları alınarak

tahmin edilmiştir.

- Hava kalitesi ve meteorolojik veriler, istasyon adı, numarası ve tarih bilgileriyle eşleştirilerek tek bir veri setine entegre edilmiştir.

2.3. Zaman Serisi Analizi ve Görselleştirme

- İşlenmiş veriler üzerinden zamana bağlı ozon konsantrasyonu değişimleri analiz edilmiştir. Bu kapsamda:
- `summaryPlot()` fonksiyonu ile genel dağılımlar,
- `timeVariation()` fonksiyonu ile saatlik, haftalık ve mevsimsel değişimler görselleştirilmiştir.
- Bu analizler, istasyon seçiminde ve modelleme öncesi değişken davranışlarının anlaşılmasında önemli rol oynamıştır.

2.4. Makine Öğrenmesi Yaklaşımı

Bu çalışmada, seçilen istasyonların hava kalitesi parametreleri (PM_{10} , $PM_{2.5}$, NO , NO_2 , SO_2 , CO) ile meteorolojik parametreler (sıcaklık, rüzgar hızı, rüzgar yönü, yağış, nem, basınç) kullanılarak ozon (O_3) konsantrasyonunu tahmin eden bir yapay sinir ağı modeli geliştirilmiştir. Model, “siyah kutu” (black-box) özellikli bir öğrenen makine yapısı olup, verilerdeki karmaşık ve doğrusal olmayan ilişkileri öğrenerek yüksek doğrulukla tahminler üretmektedir.

Oluşturulan modelde makine öğrenmesine dayalı regresyon algoritmaları, yapay sinir ağı prensipleriyle birlikte kullanılmış; böylece verilerden örüntüler çıkarılarak ek sık veya ölçülmeyen ozon değerlerinin tahmin edilmesi hedeflenmiştir. Bu yöntem, geleneksel ölçüm cihazlarının bulunmadığı alanlarda ozon konsantrasyonu tahmini yaparak sürdürülebilir ve düşük maliyetli hava kalitesi izleme çözümleri sunmayı amaçlamaktadır. Modelleme süreci Python programlama dili ve Google Colab platformunda gerçekleştirilmiştir. Kullanılan temel modeller:

- Decision Tree Regressor
- K-Nearest Neighbors (KNN) Regressor
- Random Forest Regressor
- Gradient Boosting Regressor
- DART (Dropouts meet Multiple Additive Regression Trees)’dir.

Bu modeller, scikit-learn ve xgboost kütüphaneleri kullanılarak geliştirilmiştir. Eğitim ve test verileri %80-%20 oranında ayrılmıştır.

2.5. Model Değerlendirme Metrikleri

Her modelin performansı aşağıdaki metriklerle değerlendirilmiştir:

- R^2 (Belirleme Katsayısı)
- RMSE (Kök Ortalama Kare Hata)
- MAE (Ortalama Mutlak Hata)
- MSE (Ortalama Kare Hata)

Bu metrikler, modelin doğruluk seviyesini, aşırı uyum riskini ve genel genelleme yeteneğini ölçmek için kullanılmıştır.

2.6. Özellik Önemi Analizi

Modellerin, özellikle Random Forest Regressor’ın tahminlerde hangi değişkenlere ne düzeyde ağırlık verdiği `feature_importances_` parametresi ile belirlenmiştir. Bu analiz, ozon konsantrasyonu üzerinde etkili olan başlıca

faktörlerin (NO , NO_2 , sıcaklık, nem vb.) belirlenmesine yardımcı olmuştur.

2.7. Model Transferi ve Genelleme Testi

Oluşturulan modeller, farklı istasyon verileri üzerinde test edilerek genellenebilirlikleri değerlendirilmiştir. Böylece bir bölgede eğitilen modelin başka bir istasyona uygulanabilirliği incelenmiş ve modelin pratik kullanımı test edilmiştir.


3. Uygulama

Bu çalışmada, ozon konsantrasyonunun zamansal dağılımını incelemek amacıyla Marmara Bölgesi’nden üç hava kalitesi izleme istasyonu seçilmiştir: İstanbul-Başakşehir, Edirne-Karaağaç ve Sakarya-Ozanlar. İstasyon seçiminde iki temel kriter gözetilmiştir: (i) yüksek veri yoğunluğuna sahip olmaları ve (ii) yakın çevrelerinde sıcaklık, nem, rüzgar yönü ve hızı, basınç ve yağış gibi meteorolojik değişkenlerin düzenli olarak ölçüldüğü meteoroloji istasyonlarının bulunması.

Seçilen istasyonlara ait ozon verileri R Studio ortamında openAir paketindeki “summaryPlot” ve “timeVariation” fonksiyonları (Carslaw and Ropkins, 2012) kullanılarak analiz edilmiştir.

3.1. İstasyon Bazlı Ozon Konsantrasyonlarının Değerlendirilmesi


İstanbul-Başakşehir İstasyonu (Şekil 2): Gün içinde ozon konsantrasyonları beklenildiği gibi öğleden sonra 15:00 gibi en yüksek konsantrasyona ulaşmaktadır. İlginç bir şekilde bu istasyonda, ozon seviyesinin sabah 06:00 civarında, öğleden sonra pikinden küçük olmakla beraber bir sabah piki yaptığı gözlemlenmiştir. Birçok çalışmada gece görülen ozon konsantrasyonlarındaki artışın yatay doğrultudaki taşınım, dikey karışma ve taşınım, lokal sirkülasyon gibi fiziksel nedenlere bağlı olduğu belirtilmiştir (An vd., 2024). Çin’de Lanzhou şehrinde 09:00-12:00 arasında bir sabah pikinden bahsedilen çalışmada, pikin ortamdaki petrokimya endüstrisinden kaynaklanan emisyonlardaki farklı VOClerin bulunması ile ilgili olabileceği belirtilmiştir (Guo vd., 2022). Başakşehir’de görülen bu pik için ortamdaki VOC bileşenler ve fiziksel taşınım etkilerinin belirlenerek pikin oluşum mekanizması aydınlatılabilir. Aylık bazda, ozon oluşumunda önemli faktörlerden sıcaklık ve dünyaya ulaşan ışımanın artması ile ozon konsantrasyonları yaz aylarında, özellikle Temmuz ve Ağustos’ta en yüksek değerlere ulaşmıştır. Hafta günleri bazında değişime bakıldığında en yüksek ozon konsantrasyonları Pazar günleri görülmektedir.




Şekil 2. İstanbul-Başakşehir İstasyonu için Gün, Saat, Ay Bazında Summaryplot ile Çizilmiş Ortalama Ozon Konsantrasyonları ($\mu\text{g}/\text{m}^3$). Açık renk gölgeler %95 güven aralığını göstermektedir.

Edirne-Karaağaç (Şekil 3) ve Sakarya-Ozanlar (Şekil 4) İstasyonları: Bu iki istasyonda ise klasik belirgin bir öğleden sonra piki gözlenmiştir. Öğleden sonraki ozon pik konsantrasyonu Edirne-Karaağaç'ta $70\text{--}80\ \mu\text{g}/\text{m}^3$, Sakarya-Ozanlar'da ise $50\text{--}60\ \mu\text{g}/\text{m}^3$ aralığında seyretmiştir. Aylık bazda bu iki istasyon için en yüksek değerlerin Ağustos ayında kaydedildiği görülmüştür. Sakarya-Ozanlar istasyonunda İstanbul-Başakşehir istasyonu gibi en yüksek ozon konsantrasyonu belirgin bir şekilde Pazar günleri

görülmürken, Edirne-Karaağaç istasyonunda hafta içi günlerindeki ozon konsantrasyonlarının genelde Pazar günü ozon konsantrasyonlarından daha yüksek olduğu söylenebilir. Yapılan bir çalışmaya göre A.B.D ve Almanya'da istasyonlardaki hafta içi/hafta sonu ozon farkının % 5 ile % 15 arasında olduğu belirtilmiştir (Sicard vd., 2020). Haftanın günleri bazındaki bu değişim, ozon oluşumuna neden olan öncüllerin miktar ve ortama verildikleri saatlere bağlı değişiminden kaynaklanıyor olabilir.



Şekil 3. Edirne-Karaağaç İstasyonu için Gün, Saat, Ay Bazında Summaryplot ile Çizilmiş Ortalama Ozon Konsantrasyonları ($\mu\text{g}/\text{m}^3$). Açık renk gölgeler %95 güven aralığını göstermektedir.




Şekil 4. Sakarya-Ozanlar İstasyon İstasyonu için Gün, Saat, Ay Bazında Summaryplot ile Çizilmiş Ortalama Ozon Konsantrasyonları ($\mu\text{g}/\text{m}^3$). Açık renk gölgeler %95 güven aralığını göstermektedir.

3.2. Günlük Maksimum 8 Saatlik Ozon Analizi

Seçilen üç hava kalitesi izleme istasyonuna ait O_3 verileri, R Studio ortamında *foqat* kütüphanesindeki *dm8n* fonksiyonu kullanılarak analiz edilmiştir. Bu yöntem ile, her gün için sekiz saatlik zaman dilimleri içinden en yüksek ortalama değer belirlenmiş ve bu değer günlük maksimum 8 saatlik ortalama olarak kaydedilmiştir. Türkiye Hava Kalitesi Değerlendirme ve Yönetimi yönetmeliğine göre bir yılda

maksimum günlük 8 saatlik ortalama limit değer $120 \mu\text{g}/\text{m}^3$ olarak belirlenmiştir.


İstanbul-Başakşehir İstasyonu(Şekil 5): Ozon konsantrasyonlarının büyük çoğunluğu $100 \mu\text{g}/\text{m}^3$ altında kalmıştır. Bununla birlikte, sınırlı sayıda veri $100\text{--}150 \mu\text{g}/\text{m}^3$ aralığında ve çok az sayıda örnek ise $150 \mu\text{g}/\text{m}^3$ üzerindedir. Nadir de olsa, $200 \mu\text{g}/\text{m}^3$ 'ün üzerinde değerler de kaydedilmiştir. Sayılı günde limit değerinin üzerinde bir ozon kirliliği olduğu söylenebilir.



Şekil 5. İstanbul-Başakşehir Maksimum Günlük 8 Saatlik Ozon ($\mu\text{g}/\text{m}^3$).

Sakarya-Ozanlar İstasyonu(Şekil 6): Ölçülen ozon konsantrasyonlarının neredeyse tamamı $125 \mu\text{g}/\text{m}^3$ 'ün altında


kalmıştır. Bu durum, istasyonun diğerlerine kıyasla daha düşük ozon birikimi gösterdiğini ortaya koymaktadır.



Şekil 6. Sakarya-Ozanlar Maksimum Günlük 8 Saatlik Ozon ($\mu\text{g}/\text{m}^3$).

Edirne-Karaağaç İstasyonu(Şekil 7): Sakarya-Ozanlar ile benzer bir profile sahiptir. Verilerin büyük bölümü $125 \mu\text{g}/\text{m}^3$ altındadır; ancak, $120 \mu\text{g}/\text{m}^3$ 'ü aşan değerler bulunmaktadır

ki bu istasyonun göz ardı edilemeyecek potansiyel bir ozon kirliliği vakası yaşadığını göstermektedir.



Şekil 7. Edirne-Karaağaç Maksimum Günlük 8 Saatlik Ozon ($\mu\text{g}/\text{m}^3$).

3.3. Makine Öğrenmesi ile Model Geliştirme

Çalışmada, ozon (O_3) konsantrasyonunun tahmini amacıyla birden fazla regresyon tabanlı makine öğrenmesi algoritması uygulanmış ve her modelin doğruluğu karşılaştırılmıştır. Kullanılan algoritmalar arasında Decision Tree, K-Nearest Neighbors (KNN), Random Forest, Gradient Boosting ve DART (Dropouts meet Additive Regression Trees) yer almaktadır. Her bir modele ait performans, dört temel istatistiksel metrikler kullanılarak değerlendirilmiştir.


İstanbul-Başakşehir Hava Kalitesi İzleme İstasyonu verileri üzerinde eğitilen regresyon modellerinin sonuçları Tablo II'de özetlenmiştir. İstanbul-Başakşehir İstasyonu verileriyle eğitilen sinir ağı modellerinin sonuçlarına bakıldığında (Tablo II), en iyi modelin Random Forest Regressor olduğu görülmektedir. Random Forest Regressor modeli, en yüksek R^2 (0.7791) ve en düşük RMSE (14.2891), MAE (10.3181) ve MSE (204.1789) değerleriyle en iyi performansı sergilemiştir.

Tablo II: İstanbul-Başakşehir İstasyonu Ozon Tahmin Sonuçları.


İstanbul-Başakşehir	R^2	RMSE	MAE	MSE
DecisionTreeRegressor	0.5118	21.2442	14.5249	451.3162
KNeighborsRegressor	0.6719	17.4155	12.4201	303.3003
RandomForestRegressor	0.7791	14.2891	10.3181	204.1789
Gradient Boosting	0.7094	16.3909	12.2191	268.6639
DART	0.7677	14.6548	10.7221	214.7651

Oluşturulan model için bağımsız değişkenlerinin önemini gösteren grafik ile gerçek ve tahmin verilerinin doğruluğunu gösteren grafik Şekil 8 ve 9'de verilmiştir. Bu istasyonda ozon tahminlerinin en fazla NO konsantrasyonlarından etkilendiği görülmektedir. Sonrasında ise CO ve meteorolojik parametrelerden sıcaklık en yüksek etkiye sahiptir. İstanbul-Başakşehir İstasyonu verileriyle eğitilen sinir ağı modellerinin sonuçlarına bakıldığında (Tablo II), en iyi modelin Random Forest Regressor olduğu görülmektedir. Random Forest Regressor modeli, en

yüksek R^2 (0.7791) ve en düşük RMSE (14.2891), MAE (10.3181) ve MSE (204.1789) değerleriyle en iyi performansı sergilemiştir. Şekil 9'da eğitim veri seti (mavi noktalar) ve test veri seti (turuncu noktalar) için tahmin edilen değerlerin, gerçek değerlere oldukça yakın konumlandığı görülmektedir. Noktaların kesikli diyagonal çizgi (gerçek = tahmin) etrafında yoğunlaşması, modelin hem eğitim hem de test veri seti üzerinde güçlü bir doğrusal ilişki kurabildiğini ve test verisindeki ozon değerlerini de doğru bir şekilde tahmin ettiğini göstermektedir.



Şekil 8. İstanbul-Başakşehir için Model Parametrelerinin Tartımı ($\mu g/M^3$).




Şekil 9. İstanbul-Başakşehir için Eğitim ve Test Setlerinde Ölçülen Gerçek Değerler ($\mu\text{g}/\text{M}^3$) ile Tahmin Edilen Değerler Arasındaki İlişki.

Edirne-Karaağaç Hava Kalitesi İzleme İstasyonu verileri üzerinde eğitilen yapay zeka modellerinin sonuçları aşağıdaki tabloda özetlenmiştir.


Tablo III: Edirne- Karaağaç İstasyonu Ozon Tahmin Sonuçları.

Edirne- Karaağaç	R^2	RMSE	MAE	MSE
DecisionTreeRegressor	0.3493	21.6042	15.3000	466.7453
KNeighborsRegressor	0.6129	16.6637	12.2556	277.6774
RandomForestRegressor	0.7020	14.6202	10.7106	213.7514
Gradient Boosting	0.6324	6.23732	12.5107	263.6507
DART	0.6910	14.8865	11.0918	221.6094

Oluşturulan model için özellik önemini gösteren grafik ile gerçek ve tahmin verilerinin doğruluğunu gösteren grafik aşağıda verilmiştir.



Şekil 10. Edirne-Karaağaç için Model Parametrelerinin Tartımı ($\mu\text{g}/\text{M}^3$).



Şekil 11. Edirne-Karaağaç için Eğitim ve Test Setlerinde Ölçülen Gerçek değerler ($\mu\text{g}/\text{M}^3$) ile Tahmin Edilen Değerler Arasındaki İlişki.

Edirne-Karaağaç İstasyonu verileriyle eğitilen yapay zeka sinir ağı modellerinin sonuçlarına bakıldığında (Tablo III), en iyi model olan Random Forest Regressor, en yüksek R^2 değeri (0.7020) ile en iyi performansı sergilemiştir. Ayrıca RMSE ve MAE değerlerinin diğer modellere kıyasla daha düşük olması, tahminlerinin daha doğru olduğunu göstermektedir.

Özellikle model değişkenlerinin önem grafiğine (Şekil 10) bakıldığında, sıcaklık önemli özellik olarak belirlenmiş ve bu durum ozon seviyesi tahmininde sıcaklığın büyük rol oynadığını ortaya koymuştur. NO_x ve NO_2 gibi kirleticiler de önemli özellikler arasındadır. Nem ve rüzgar yönü gibi meteorolojik veriler de ozon tahmininde önemli bir


rol üstlenmektedir. Bu analizler sonucunda, ozon tahmini için Random Forest Regressor modelinin en iyi performansı gösterdiği ve azot oksitler ve sıcaklığın en kritik öneme sahip olduğu görülmektedir. Şekil 11 incelendiğinde, eğitim veriseti (mavi noktalar) ve test veriseti (turuncu noktalar) için tahmin edilen değerlerin, gerçek değerlere oldukça yakın konumlandığı görülmektedir. Buradan hareketle model güçlü bir doğrusal ilişkiyi ortaya koymuş ve modelin aşırı öğrenmeden (overfitting) kaçınarak genellenebilir bir başarı elde ettiği söylenebilir.

Sakarya-Ozanlar Hava Kalitesi İzleme İstasyonu verileri üzerinde eğitilen yapay zeka modellerinin sonuçları Tablo IV'de özetlenmiştir.


Tablo IV: Sakarya-Ozanlar İstasyonu Ozon Tahmin Sonuçları.

Sakarya- Ozanlar	R^2	RMSE	MAE	MSE
DecisionTreeRegressor	0.5144	21.1887	14.5101	448.96283
KNeighborsRegressor	0.6719	17.4155	12.4201	303.3003
RandomForestRegressor	0.7779	14.3277	10.3337	205.2844
Gradient Boosting	0.7094	16.3909	12.2191	268.6639
DART	0.7677	14.6548	10.7221	214.7651

Oluşturulan model için özellik önemini gösteren grafik ile gerçek ve tahmin verilerinin doğruluğunu gösteren grafik aşağıda verilmiştir.



Şekil 12. Sakarya-Ozanlar için Model Parametrelerinin Tartımı ($\mu\text{g}/\text{M}^3$).



Şekil 13. Sakarya-Ozanlar Gerçek Değer ve Tahmin Sonuçları Grafiği ($\mu\text{g}/\text{M}^3$).

Sakarya-Ozanlar İstasyonu verileriyle eğitilen yapay zeka sinir ağı modellerinin sonuçları incelendiğinde (Tablo IV), en iyi modellerin Random Forest Regressor ve DART olduğu görülmektedir. Her iki modelde de R^2 , RMSE, MAE ve MSE değerleri birbirine oldukça yakındır. Özellik önem grafiğine (Şekil 12) bakıldığında, NO_x ve NO gazlarının ozon tahminindeki en kritik özellikler olduğu anlaşılmaktadır. Sıcaklık ve nem de önemli faktörler arasındadır. Grafik ve tablodaki veriler, doğru özellik seçimi ve model optimizasyonu yapıldığında ozon seviyesinin yüksek doğrulukla tahmin edilebileceğini göstermektedir.

Test setindeki mavi noktalar genellikle kesikli çizgiye yakın konumlanmış ve doğrusal bir eğilim sergilemektedir

(Şekil 13). Bu durum, modelin eğitim sırasında öğrendiği bilgileri test setine başarıyla uyguladığını işaret etmektedir. Yüksek değerlerde (örneğin 150 ve üzeri) bazı noktaların kesikli çizgiden sapması, modelin bu değerlerde tahmin yapmakta zorlandığını veya daha büyük hatalar yaptığını gösterebilir. Düşük ve orta değerlerde (0-125 arası) noktaların çoğu kesikli çizgiye daha yakın ve daha az dağınıktır; bu da modelin bu aralıklarda daha doğru tahminler yaptığını kanıtlamaktadır. Eğitim seti (turuncu) ile test seti (mavi) arasında belirgin bir fark olmaması, modelin genel performansının tutarlı olduğunu ve aşırı uyum (overfitting) göstermediğini ortaya koymaktadır. Modelin iyi bir genelleme yeteneğine sahip olduğu sonucuna varılabilir.


Elde edilen sonuçlara göre, genel olarak Random Forest Regressor algoritması, tüm istasyonlarda en yüksek performansı göstermiştir. Örneğin:

- İstanbul-Başakşehir istasyonu için: $R^2 = 0.7791$, $RMSE = 14.29 \mu g/m^3$
- Edirne-Karaağaç istasyonu için: $R^2 = 0.7020$, $RMSE = 14.62 \mu g/m^3$
- Sakarya-Ozanlar istasyonu için: $R^2 = 0.7779$, $RMSE = 14.33 \mu g/m^3$

Tüm istasyonların birleşik verisiyle oluşturulan genel modelde ise $R^2 = 0.7558$ olarak hesaplanmış ve güçlü bir genelleme başarısı sergilemiştir. Bu sonuçlar, Random Forest modelinin hem bireysel hem de çoklu istasyon verileriyle etkili tahminler yapabileceğini göstermektedir. Tablo 5’de tüm istasyon verileri kullanılarak yapılan modelin farklı algoritmalar için hesaplanan model performans parametreleri verilmiştir.

Tablo V: Eğitim için Tüm İstasyon Verilerinin Kullanılarak Ozon Tahmin Modeli Sonuçları.

Tüm İstasyonlar	R^2	RMSE	MAE	MSE
DecisionTreeRegressor	0.4842	21.5309	15.0181	463.5813
KNeighborsRegressor	0.6626	17.4152	12.7522	303.2892
RandomForestRegressor	0.7558	14.8149	10.8847	219.4837
Gradient Boosting	0.6344	18.1261	13.9375	328.5572
DART	0.7200	15.8629	11.9575	251.6337



Şekil 14. Tüm İstasyonlar için Model Parametrelerinin Tartımı ($\mu g/M^3$).

Ayrıca, değişken önem analizi uygulanarak her bir bağımsız değişkenin model üzerindeki etkisi belirlenmiştir (Şekil 14). Bu analiz sonucunda:

- NO ve NO₂ gibi azot oksit bileşenlerinin,
- Sıcaklık ve nem gibi meteorolojik değişkenlerin,

ozon tahmininde en kritik girdiler olduğu anlaşılmıştır. Buna karşın yağış ve basınç gibi değişkenler daha düşük etkiye sahip bulunmuştur.

4. Sonuçlar

Bu çalışmada, Marmara Bölgesi'nde seçilen üç hava kalitesi izleme istasyonuna ait O₃ verileri; meteorolojik ve diğer kirlenici parametrelerle birlikte analiz edilerek, ozon konsantrasyonunun zamansal dağılımı ve tahmini üzerine kapsamlı bir değerlendirme gerçekleştirilmiştir. R Studio ortamında zaman serisi analizleri (*summaryPlot*, *timeVariation*) uygulanmış; saatlik, haftalık ve aylık değişimler incelenmiştir. Çalışma kapsamında elde edilen bulgular aşağıdaki şekilde özetlenebilir:

- Ozon konsantrasyonları, istasyonların çoğunda Temmuz ve Ağustos aylarında artış göstermiştir. Bu artış, sıcaklıkla birlikte fotokimyasal reaksiyonların hızlanmasından kaynaklanmaktadır.
- Haftalık analizler, ozon seviyesinin iki istasyonda özellikle Pazar günleri en yüksek değerlere ulaştığını ortaya koymuştur.
- İstanbul'daki Başakşehir istasyonu gün içinde çift pik davranışı sergilerken; diğer istasyonlarda tek tepe noktası gözlenmiştir.
- *dm8n* fonksiyonu ile hesaplanan günlük maksimum 8 saatlik ortalama ozon değerleri, çoğu istasyonda genel olarak 125 µg/m³ sınırının altında kalmıştır. Ancak İstanbul-Başakşehir ve Edirne-Karaağaç istasyonlarında zaman zaman 150-200 µg/m³'ü aşan değerler de kaydedilmiştir.

Çalışmada makine öğrenmesine ait regresyon modelleri ile ozon konsantrasyonları $0.78=R^2$ değeriyle tahmin edilebilmektedir. Beş farklı regresyon algoritması test edilmiş; özellikle Random Forest Regressor modeli, tüm istasyonlarda en

yüksek performansı göstermiştir ($R^2 > 0.75$). Model, hem bireysel istasyon verileriyle hem de tüm istasyonların birleşik verisiyle genellenebilir tahmin gücüne sahiptir.

Ayrıca yapılan özellik önemi (feature importance) analizi, ozon tahmininde NO, NO₂ ve sıcaklık gibi değişkenlerin kritik rol oynadığını göstermiştir. Bu bulgu, ozon oluşumunun temel bileşenlerine dair bilimsel literatürü destekler niteliktedir. Ancak sabah piki de görülen Başakşehir istasyonunda CO, modeli etkileyen en önemli üç parametreden biri olması, bu nokta için farklı bir UOB bileşiminin varlığından veya hava koşulları, hava kütlelerinin geldiği konumdan kaynaklanabilir. Çin'de 2017 için yapılan bir çalışmada, Ozon ile CO arasındaki korelasyonun farklılık gösterebileceği ve bazı şehirlerde negatif korelasyon bazı şehirlerde ise pozitif korelasyonlar görüldüğü belirtilmiştir (Wang vd., 2019). Başakşehir istasyonu için, UOB türlerinin ölçülmesi, hava kütlelerinin taşınım rotalarının belirlenmesi gibi daha detaylı analizlerle ozon oluşum mekanizması ortaya çıkarılabilir.

Genel olarak çalışma, ozon izleme altyapısının yetersiz olduğu bölgelerde makine öğrenmesi temelli tahmin modellerinin, etkili ve düşük maliyetli bir alternatif sunabileceğini ortaya koymaktadır. Geliştirilen yöntem, hava kalitesi yönetimi, sağlık risk değerlendirmesi ve erken uyarı sistemleri açısından uygulanabilir bir çerçeve sunmaktadır.

Son olarak saatlik ısıma değerleri ve trafik durumu verileri gibi daha fazla parametrenin modele eklenmesiyle ve aşamalı model uygulamalarıyla modelin tahmin etme başarısı artırılabilir.

Teşekkür

Bu çalışma TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı (BİDEB) tarafından yürütülen, 2209-A

Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında desteklenmiştir.

Kaynakça

- Ahmad, M., Rappenglück, B., Osibanjo, O. O., & Retama, A. (2022). A Machine Learning Approach to Investigate The Build-Up of Surface Ozone in Mexico-City. *Journal of Cleaner Production*, 379. Retrieved from <https://doi.org/10.1016/j.jclepro.2022.134638>
- An, C., Li, H., Ji, Y., Chu, W., Yan, X., & Chai, F. (2024, April 15). A Review on Nocturnal Surface Ozone Enhancement: Characterization, Formation Causes and Atmospheric Chemical Effects. *Science of the Total Environment*. Elsevier B.V. Retrieved from <https://doi.org/10.1016/j.scitotenv.2024.170731>
- Ayus, I., Natarajan, N., & Gupta, D. (2023). Comparison of Machine Learning and Deep Learning Techniques for The Prediction of Air Pollution: A Case Study from China. *Asian Journal of Atmospheric Environment*, 17, 4. Retrieved 28 April 2025 from <https://doi.org/10.1007/s44273-023-00005-w>
- Cao, Y., Zhao, X., Su, D., Cheng, X., & Ren, H. (2023). A Machine-Learning-Based Classification Method for Meteorological Conditions of Ozone Pollution. *Aerosol and Air Quality Research*, 23(1). Retrieved from <https://doi.org/10.4209/aaqr.220239>
- Cheng, Y., Huang, X. F., Peng, Y., Tang, M. X., Zhu, B., Xia, S. Y., & He, L. Y. (2023). A Novel Machine Learning Method for Evaluating The Impact of Emission Sources on Ozone Formation. *Environmental Pollution*, 316. Retrieved from <https://doi.org/10.1016/j.envpol.2022.120685>
- Du, J., Qiao, F., Lu, P., & Yu, L. (2022). Forecasting Ground-Level Ozone Concentration Levels Using Machine Learning. *Resources, Conservation and Recycling*, 184, 106380. Retrieved 17 April 2025 from <https://doi.org/10.1016/J.RESCONREC.2022.106380>
- Guo, W., Chen, Q., Yang, Y., Zhang, Y., Liu, X., Zhang, R., Zhu, Y., Li, G., Liu, P., Chen M. (2022) Investigating the Mechanism of Morning Ozone Concentration Peaks in a Petrochemical Industrial City Atmos. *Environ.*, 270, Article 118897, <https://doi.org/10.1016/j.atmosenv.2021.118897>
- Hong, F., Ji, C., Rao, J., Chen, C., & Sun, W. (2023). Hourly Ozone Level Prediction Based on the Characterization of its Periodic Behavior via Deep Learning. *Process Safety and Environmental Protection*, 174, 28–38. Retrieved 17 April 2025 from <https://doi.org/10.1016/J.PSEP.2023.03.059>
- Hosseinpour, F., Kumar, N., Tran, T., & Knipping, E. (2024). Using Machine Learning to Improve the Estimate of U.S. Background Ozone. *Atmospheric Environment*, 316. Retrieved from <https://doi.org/10.1016/j.atmosenv.2023.120145>
- Jiménez-Navarro, M. J., Martínez-Ballesteros, M., Martínez-Álvarez, F., & Asencio-Cortés, G. (2024). Explaining Deep Learning Models for Ozone Pollution Prediction via Embedded Feature Selection. *Applied Soft Computing*, 157. Retrieved from <https://doi.org/10.1016/j.asoc.2024.111504>
- Kuo, C. P., & Fu, J. S. (2023). Ozone Response Modeling to NOx and VOC Emissions: Examining Machine Learning Models. *Environment International*, 176. Retrieved from <https://doi.org/10.1016/j.envint.2023.107969>
- Lyu, Y., Ju, Q., Lv, F., Feng, J., Pang, X., & Li, X. (2022). Spatiotemporal Variations of Air Pollutants and Ozone Prediction Using Machine Learning Algorithms in The Beijing-Tianjin-Hebei Region from 2014 to 2021. *Environmental Pollution*, 306. Retrieved from <https://doi.org/10.1016/j.envpol.2022.119420>
- Mu, X., Wang, S., Jiang, P., & Wu, Y. (2023). Estimation of Surface Ozone Concentration Over Jiangsu Province Using a High-Performance Deep Learning Model. *Journal of Environmental Sciences*, 132, 122–133. Retrieved 17 April 2025 from <https://doi.org/10.1016/J.JES.2022.09.032>
- Sicard P, Paoletti E, Agathokleous E, Araminiené V, Proietti C, Coulibaly F, De Marco A. Ozone Weekend Effect in Cities: Deep Insights for Urban Air Pollution Control. *Environ Res.* 2020 Dec;191:110193. doi: 10.1016/j.envres.2020.110193
- Wang Z.S., Lv J., Tan Y., Guo M., Gu Y., Xu S., Zhou Y. (2019) Temporospatial Variations and Spearman Correlation Analysis of Ozone Concentrations to Nitrogen Dioxide, Sulfur Dioxide, Particulate Matters and Carbon Monoxide in Ambient Air, China *Atmospheric Pollution Research* 10 (4), 1203–1210 2019
- Wu, C. lin, He, H. di, Song, R. feng, & Peng, Z. ren. (2022). Prediction of Air Pollutants on Roadside of the Elevated Roads With Combination of Pollutants Periodicity and Deep Learning Method. *Building and Environment*, 207. Retrieved from <https://doi.org/10.1016/j.buildenv.2021.108436>
- Yafouz, A., Najah Ahmed, A., Zaini, atiah, Sherif, M., Sefelnasr, A., & El-Shafie, A. (2021). Hybrid Deep Learning Model for Ozone Concentration Prediction: Comprehensive Evaluation and Comparison with Various Machine and Deep Learning Algorithms Hybrid Deep Learning Model for Ozone Concentration Prediction: Comprehensive Evaluation and Comparison with Various Machine and Deep Learning Algorithms, 15(1), 902–933. Retrieved 17 April 2025 from <https://doi.org/10.1080/19942060.2021.1926328>