

DÜŞÜK MALİYETLİ VE TAŞINABİLİR PARTİKÜL MADDE (PM) SENSÖRLERİNİN KALİBRASYONU

Calibration of Low-Cost and Portable Particulate Matter (PM) Sensors

Çağrı Şahin
Sait Cemil Sofuoğlu

ÖZET

Havadaki partiküller, özellikle mikron-altı fraksiyondakiler (PM₁, aerodinamik çapı 1 µm'den az olan partiküller) sağlığa zararlı etkileri nedeniyle küresel bir endişe kaynağıdır. İç hava partikül madde konsantrasyonlarının izlenmesi tipik olarak, genellikle modelleme veya enterpolasyon yoluyla tahmin edilen uzamsal kapsamdaki boşluklara sahip az sayıda sabit izleme cihazları kullanılarak gerçekleştirilir. Fakat iç ortamların hacmi büyüdükçe noktasal olarak veri üreten bu cihazların, tüm alanı temsil etmeleri zorlaşmaktadır. Bu nedenle, çalışmalarda kullanılan cihazların sayısal olarak artırılması gerekmektedir. Bu durum ise düşük maliyetli ve taşınabilir hava kalitesi izleme cihazlarına olan talebi artırmaktadır. İzleme cihazı maliyetlerinin yüksekliği nedeniyle, düşük maliyetli ve taşınabilir sensörler tercih edilse de, bu sınıfta yer alan sensörlerin gerçeğe yakın sonuçlar üretebilmesi, daha güvenilir bir başka referans cihaz ile test edilmesi ile mümkün olmaktadır. Ayrıca, saha çalışmalarında faydalı olabilmesi için bu sensörlerin kesinlik ve doğruluğunun değerlendirilmesi gerekmektedir.

Düşük maliyetli sensörler (DMS'ler), genellikle partikül maddeler için üretilen optik parçacık sayıcılar (OPC'ler), kullanıma hazır bir şekilde kullanıcıya teslim edilmesine rağmen, tam zamanlı veri üretmeleri ve uzaktan kontrol edilmeleri için bir IoT (Internet of Things – Nesnelerin interneti) sisteme uyum sağlayarak çalıştırılması gerekliliği; uzun süreli performanslarının, ışık saçılımı algılama konfigürasyonlarının optimize edildiği bir diğer cihazla karşılaştırılarak kalibre edilmelerini gerektirmektedir.

Bu çalışmada, PM izlemek üzere üretilmiş bir marka OPC'lerin, kesinliği ve doğruluğu sertifikalandırılmış bir izleme cihazı referans alınarak doğru veri üretme durumları incelenmiştir. Düşük maliyetli ve taşınabilir PM sensörlerinin performansı; farklı boyut dağılımlarının etkileri, sıcaklık, nem ve çığ noktası gibi parametrelerin kullanıldığı çok değişkenli doğrusal regresyon, yapay zeka veya makine öğrenmesi yöntemleri ile incelenmiş olup böylece, kalibre edilmiş OPC'lerin, derslikler gibi kalabalık iç ortamların her noktasında, partikül maddeye bağlı kirletici maruziyetlerinin değerlendirilmesi mümkün olacaktır.

Anahtar Kelimeler: Partikül madde, PM₁, sensör, IoT, makina öğrenmesi, yapay zeka, kalibrasyon.

ABSTRACT

Airborne particles, especially those in the sub-micron fraction (PM₁, particles with an aerodynamic diameter less than 1 µm), are a global concern due to their harmful effects on health. Monitoring indoor particle matter concentrations are typically carried out using a limited number of fixed monitoring devices with spatial gaps, often requiring use of modeling or interpolation. However, as the volume of indoor environments increases, it becomes increasingly difficult for these point data-generating devices to represent the entire area. Therefore, the number of sensors used in studies needs to be increased. In turn, the demand for low-cost and portable air quality monitoring devices increases. The low-cost sensors generally have high levels of uncertainty. However, it is possible to

obtain realistic results from these sensors by testing them with a more reliable reference device. Additionally, it is necessary to evaluate the accuracy and precision of these sensors in order to be helpful in field studies.

Although low-cost sensors (LCSs) are often delivered ready-to-use by manufacturers, they need to be operated by integrating with an IoT (Internet of Things) system to produce real-time data, and be remotely controlled. This requirement necessitates a calibration and optimization that considers their long-term performance.

This study compares the accuracy and precision of OPCs produced for particulate matter monitoring with a certified monitoring device. The performance of low-cost and portable sensors has been improved by performing a calibration study using multiple linear regression and artificial intelligence or machine learning methods that evaluate the effects of different size distributions, temperature, humidity, and dew point parameters. As a result, the calibrated OPCs can be used to study particulate matter exposure in crowded indoor environments, such as classrooms.

Key Words: Particulate matter, PM₁, sensor, IoT, machine learning, calibration.

1. GİRİŞ

Havadaki partikül madde (PM) kirliliğine maruziyet, dünya genelinde akciğer kanseri, iskemik kalp hastalığı, inme ve kronik obstrüktif akciğer hastalığı (KOAH) gibi hastalıklara bağlı yılda 4,2 milyon ila 8,9 milyon kişinin ölümüne neden olmaktadır [1–3]. COVID-19 pandemisi öncesinde yapılan bir araştırmaya göre, iç ortamdan kaynaklı PM maruziyeti için Türkiye’de toplam atfedilen ortalama erken ölüm oranı 6679/100000 kişi olarak verilmiştir (DSÖ, 2019). PM genellikle ortalama aerodinamik çapına göre, <10 µm (PM₁₀), <2,5 µm (PM_{2,5}), <1 µm (PM₁) ve <0,1 µm (PM_{0,1}) sırasıyla, kaba, ince, mikron-altı ve ultra ince olarak sınıflandırılırlar. Solunum yolu ile alınan PM sınıfları için, PM₁₀ solunum sistemine, PM_{2,5} bronşiyoller ile potansiyel olarak alveollere, PM₁ akciğer alt lobu ve alveollere ve PM_{0,1} ise hava-kan bariyerine aşarak dolaşım sistemine girebilmektedir [3,5]. Solunum yolu ile solunum sistemi ve akabinde dolaşım sistemine girebilen bu kirletici grubu için çalışmalar PM_{2,5} ve PM₁₀’un etkileri üzerinde odaklanmış, daha ince partiküllerin potansiyel olarak daha fazla sağlık etkilerine neden olacağı düşüncesiyle, PM₁ için çalışmaların azlığı günümüzde endişe kaynağı olarak değerlendirilmiştir [5]. Bugüne kadar, PM₁ çalışmalarının çoğu toplum sağlığı riski üzerinde içlerinde hipertansiyon, kardiyovasküler hastalıklar ve otizm spektrum bozukluğu gibi uzun vadeli etkilere odaklanmıştır. Kısa vadeli maruziyetin neden olduğu kardiyovasküler hastalıklara bağlı ölümler ve genellikle zatürre ve KOAH nedenli acil servis başvuruları [6–8] PM₁ kirliliğinin insan sağlığını ne denli etkileyebileceğini göstermekte ancak PM₁ için uluslararası veya ulusal dış veya iç hava sınır değeri bulunmamaktadır.

Yüksek değişkenliğe sahip olan mikro çevrelerde, ince partikül maddeler gibi kirleticilerin haritalanmasını zorlaştıracak farklılıklar oluşmaktadır [9,10]. İlgili mekânsal değişimleri değerlendirmek için yoğun izleme ağlarına ihtiyaç duyulmaktadır. Gerçek zamanlı partikül madde verilerinin toplanması ve gerekli eylemlerin uygulanması amacına yönelik dünya çapında mevcut bir eğilim vardır [11–13]. Partikül maddelerin oluşum dinamiklerindeki değişkenlikler nedeniyle, mekânsal ve zamansal kirlilik seviyelerinde önemli farklılıklar oluşmaktadır. Referans cihazlar ile oluşturulan izleme ağları, her bir iç ortam referans izleme cihazının yüksek maliyete sahip olması nedeniyle kısıtlıdır. Partikül maddeler ve gazlar dâhil olmak üzere havadaki çok çeşitli türlerin konsantrasyonlarını ölçmek için düşük maliyetli sensörlerin (DMS) geliştirilmesi bu denli zorlukların üstesinden gelmek için uygun bir seçenek oluşturmaktadır [14–17].

DMS, Amerikan Çevre Koruma Ajansı (USEPA) tarafından belirtilen maliyeti 2500 \$’dan az olan cihazlar için tanımlanmış olsa da [18], günümüzde bu değer 100 \$ altındaki cihazlar için kullanılmaya başlanmıştır [19,20]. DMS’ler, elektrokimyasal hücre (EC), metal oksit yarı iletken (MOS), dağılmayan kızılötesi (NDIR) gibi teknolojiler kullanırken, PM için parçacık ışık saçılımı teknolojisini kullanan optik

parçacık sensörleri (OPS'ler) kullanılmaktadır. OPS'ler, nefelometreler ve optik partikül sayıcılar (OPC'ler) olmak üzere iki ana gruba ayrılabilirler [21]. Işık saçılımı kullanan bu iki teknolojiyen nefelometreler, parçacıkları topluluk halinde ölçerken, OPC'ler parçacıkları ayrı ayrı algılar, sayıları ve boyutları hakkında bilgi verir. Optik yöntemler doğrudan kütle konsantrasyonlarını ölçmez; bunun yerine, ışık saçılımı verilerini parçacık sayısı ve kütlesine dönüştüren kalibrasyonlara dayalı olarak kütle tahmin ederler. Muadilleri arasında en düşük maliyete sahip ama farklı PM boyutları hakkında bilgi vermesi açısından avantaja sahip olan OPC'ler için veri kalitesinin, yani belirsizlik düzeyinin, yeterli olup olmayacağı sorusu tartışılmaya devam etmektedir [13,22]. Hem gazlar hem de partikül sensörleri için bağıl nem (RH), sıcaklık ve diğer gaz fazı bileşikler gibi birçok etmen girişim yaratabilir [14,23,24]. Yüksek RH, kuru kütle tahmin edilmesine yol açan higroskopik partikül büyümesine neden olabilmekte ve partikül madde fraksiyonunun doğru tahminini zorlaştırmaktadır. Bu zorluklara rağmen, son çalışmalar OPC'lerin, bilinen girişimler için uygun düzeltmelerin uygulanması şartıyla büyük ölçekli çalışmalarda kullanabileceğini göstermiştir [12,19,23,25].

OPC'ler için, literatürde rapor edilen veri üretim kalitesi performansları değişkenlik göstermektedir [12,26–28]. Birçok üretici firmadan ticari olarak temin edilebilen çok çeşitli düşük maliyetli OPC'ler bulunmaktadır. OPC'lerin doğruluk ve kesinlik açısından yerleşik cihazlarla rekabet etmesi beklenmemekle birlikte, satın alınabilirlikleri ve boyutları, kişisel izleme gibi bir dizi çalışmada bu tür sensörlerin kullanımı için onları çekici kılmaktadır. Ancak bu tür çalışmalarda faydalı olabilmesi için bu cihazların kesinlik ve doğruluğunun değerlendirilmesi gerekmektedir. Referans cihazlarla laboratuvar ortamında test edilen OPC'lerin performans değerlendirmeleri yeterli hassasiyetler ile umut verici sonuçlar göstermişlerdir [29]. Bir çalışmada, Alphasense firmasından temin edilen OPC-N2 marka sensörlerin, referans aerosoller (yol tozu, NaCl ve ark kaynağı ile üretilen duman) kullanan ve GRIMM marka taşınabilir aerosol spektrofotometre cihazı arasında boyut dağılımları ve parçacık kütlesi için kalibrasyonlar ile değerlendirmişlerdir [27]. Çalışmada aerosol spektrofotometre cihazı ile OPS'nin ürettiği veriler arasında anlamlı bir yakınlık görülmüştür. Referans aerosoller kullanarak laboratuvar ortamında gerçekleşen çalışmalarda sonuçlar umut verici olsa da, gerçek zamanlı alınan saha çalışmalarında karşılaşılan bazı karmaşıklıklar ile nem ve sıcaklık gibi parametrelerin veri kalitesi ve cihaz performansını düşürmesi nedeniyle ölçülen değerler gerçek konsantrasyonları temsil etmeyebilmektedir. OPC'lerin referans cihazlar ile testlerinin gerçekleştiği kısa süreli (4-5 gün) saha çalışmalarında iki farklı OPC tipi sensörün [30-31], kentsel ve kırsal dış hava ölçümlerinde iyi bir performans sergilediği belirtilmiştir. Bu durumun aksine yol kenarında konumlandırılmış partikül madde konsantrasyonunun izlenmesinin amaçlandığı iki OPC'nin referans cihazla kıyaslandığı bir başka çalışmanın sonuçları, OPC'lerin zayıf bir veri kalitesine sahip olduğunu göstermiştir [12]. Literatürden elde edilen sonuçlarda bu tür çelişkili bulguların yer alması nedeniyle, DMS'lerin referans cihazlarla test edilmesinin önemi anlaşılmakta, bu tip cihazlarının ölçüm stabilitesinin ve uzun ömürlülüğünün daha uzun vadeli değerlendirilmesi çalışmalarına ihtiyaç duyulmaktadır.

OPC'ler için kurulan kalibrasyon modelleri tipik olarak referans monitör ölçümlerini kullanarak yanlılığı ayarlayarak OPC'deki sistematik hatayı ve OPC ölçümlerinin sıcaklık, RH, gibi ortam partikül özelliklerini etkileyen çevresel koşullara bağımlılığını düzeltir [13]. PM₁ için düşük maliyetli sensörlerin kalibrasyonu hakkında az sayıda çalışma bulunmaktadır [19,32]. Çalışmalar çoğunlukla PM_{2.5} üzerindeki hesaplamalara dayanmaktadır [13,33–38]. Bunun nedeni, 2021'de USEPA (Amerikan çevre koruma ajansı) tarafından yayınlanan "Performance Testing Protocols, Metrics, and Target Values for Fine Particulate Matter Air Sensors: Use in Ambient, Outdoor, Fixed Site, Non-Regulatory Supplemental and Informational Monitoring Applications" bölümünde partikül madde sensörlerinin performans değerlendirmelerini belirleyen kurallardır [39]. OPC genel olarak referans cihazlar ile değerlendirilmesi istatistiksel verilere bağlanmıştır. Bunların en başında OPC ve referans cihazların korelasyonu (Pearson korelasyonu r sabiti) değerlendirilmiş ve daha sonrasında basit doğrusal regresyon (BDR) modelinde verilen belirleme katsayısı (R²) ile ortalama karekök sapması (RMSE) değerlendirilmiştir.

Bu çalışma, kalibrasyon modelleri oluşturmak için gelişmiş makina öğrenimi algoritmaları kullanarak iç hava partikül madde izlemesi için piyasada bulunan OPC-R2 sensörlerinin performansını değerlendirmeyi ve veri güvenilirliğini artırmayı amaçlamaktadır. Bilinen literatürde OPC-R2 cihazları ile yapılan kalibrasyon çalışması mevcut değildir. Ayrıca bu çalışmada, çoklu doğrusal regresyon

(ÇDR), rastgele karar ormanları (RF) ve destek vektörü regresyon (SVR) gibi kalibrasyon modellerini değerlendirilmiş ve karşılaştırılmıştır.

2. GEREÇ VE YÖNTEM

2.1. Kullanılan Cihazlar

Sensörler ve referans cihazlarla veri üretimi Ağustos-Eylül 2022 tarihleri arasında laboratuvar ortamında birbirilerini etkilemeyecek en yakın mesafede konumlandırılarak gerçekleştirilmiştir. Her cihaz için yaklaşık 10000 veri üretilerek (sensörlerin veri vermediği süre ve nem oranının yüksek olduğu >%70 koşullarda alınan verilerin çıkarılması hesaba katıldığında) kalibrasyon çalışmaları gerçekleştirilmiştir. Cihazların zamana bağlı hatalı sonuçlar üretmesini engellemek için bir saatlik ortalama veriler kullanılmıştır. Çalışmada değerlendirilen OPC, Alphasense (<http://www.alphasense.com>) tarafından ticari olarak üretilen OPC-R2'dir (Şekil 1). Geleneksel optik partikül sayıcılar gibi, OPC-R2 de bir lazer ışını yoluyla hava akımında taşınan ayrı parçacıklar tarafından saçılan ışığı ölçer. Bu ölçümler, partikül boyutunu¹ ve partikül sayısı konsantrasyonunu belirlemek için kullanılır. Partikül kütle yüklemeleri (PM₁, PM_{2.5} ve PM₁₀), daha sonra bir partikül yoğunluğu ve kırılma indisi (RI) varsayılarak partikül boyutu spektrumları ve konsantrasyon verilerinden hesaplanır. Ölçülen partikül sayısı konsantrasyonu, Avrupa Standardı EN481²'e göre PM₁, PM_{2.5} ve PM₁₀ boyut fraksiyonu için yerleşik fabrika kalibrasyonu yoluyla partikül kütle konsantrasyonlarına dönüştürülür. Varsayılan ayarlarda, ağırlık indeksi 2, yoğunluk 1,65 g/ml ve kırılma indisi (RI) 1,5+i0 olarak belirlenmiştir. Çoğu ticari OPC ile uyumlu olması amacıyla, şekilden bağımsız olarak tüm parçacıkların küresel olduğu varsayılır ve bu nedenle 'küresel eşdeğer boyut' atanır. Bu boyut, bilinen boyut ve kırılma indisine (RI) sahip küreler tarafından saçılmayı tahmin etmek için kesin bir teori olan Mie teorisi tarafından tanımlandığı gibi parçacık tarafından saçılan ışığın ölçümü ile ilgilidir. OPC-R2, bilinen bir çapa ve bilinen RI'ye sahip Polistiren Küresel Lateks Parçacıkları (PSL'ler) kullanılarak kalibre edilir. Farklı yoğunluk veya kırılma indisine sahip parçacıklardan kaynaklanan hatalar için düzeltme faktörleri uygulanabilir.




Şekil 1. OPC-R2 görseli.

Saniyedeki maksimum partikül ve algılanabilen maksimum kütlelerin elektronik aksamın potansiyel performansına bağlı olduğunu ve gerçek ölçümlerde azalacağı firma tarafından belirtilmiştir. Ortaya çıkan parçacık boyutu histogramları, 1 ila 30 saniyelik süre boyunca kullanıcı tanımlı örnekleme süreleri ile değerlendirilebilir. Lazer, OPC-R2'de %25 görev döngüsüne sahiptir ve iki saniyeden büyük örnekleme süreleri tavsiye edilir. Bu histogram verileri, bir SPI arabirimi aracılığıyla bir ana bilgisayara iletilir. OPC-R2, ünite içinde partikül birikimini en aza indirecek ve böylece tozlu ortamlarda uzun süreli gözetimsiz çalışmaya izin verecek şekilde tasarlanmıştır.

¹ Mie saçılım teorisine dayalı bir kalibrasyon yoluyla saçılan ışığın yoğunluğu ile ölçülür.

² PM₁₀ için EN 481 standart tanımı, OPC-R2'nin ölçülebilir üst boyut sınırının ötesindeki parçacık boyutlarını kapsar. Bazı durumlarda rapor edilen PM₁₀ değerinin %10 daha az okunmasına neden olabilmektedir.

OPC-R2, firma tarafından sağlanan bir yazılım kullanarak bir kişisel bilgisayar aracılığıyla verileri kaydetmek için tasarlanmıştır. Fakat aynı anda birden fazla OPC-R2 kullanıldığında veya uzun süreli kişisel izleme yapılması istendiğinde yazılımı kullanmak uygun olmayabilmektedir. Bu nedenle, mikrodenetleyici sistemi kullanarak, karşılaştırmalar sırasında OPC-R2'den aktarılan verileri kaydetmek için özel olarak oluşturulmuş bir sistem geliştirilmiştir. SPI arabirimi ile mikrodenetleyiciye bağlanan OPC, voltaj düzenleyici kartı ile sabit 5V ile beslenmektedir. Oluşturulan sistem Şekil 2'de verilmiştir.



Şekil 2. Sensör için oluşturulan sistemin görseli.

OPC-R2'den aktarılan verilerin mikrodenetleyici sistemine aktarılması SPI birimi sayesinde taşınan ve üretici firma tarafından hazırlanan özel bir kod ile gerçekleşmektedir. Bu kod, bir Arduino UNO veya Leonardo gibi bir mikrodenetleyici üzerinde çalışan açık ölçekli OPC cihazını kontrol etmek için yazılmıştır. Kod, OPC cihazının seri numarasını ve bilgi metnini okur, cihazı başlatır ve konfigürasyon verilerini alır. Ayrıca, cihazın 10 saniyelik aralıklarla histogram verilerini almasını ve bunları seri port üzerinden yazdırmasını sağlar. OPC cihazının çalışmasını kontrol etmek için watchdog timer ve SPI arayüzünü kullanır. Fakat yazılan kodun sistem ile bütünleştirilmesi kullanıcıya aittir. Mikrodenetçiden okunan verinin bir depolama aygıtına veya bir depolama ağına aktarılması günlük olarak verilerin değerlendirilmesi için önemlidir. Ayrıca, IoT (Internet of Things) sistemlerinde veri depolama için bulut tabanlı hizmetler de kullanılabilir. OPC'lerden üretilen verilerin internet ortamına aktarılması server ve ağ bakım ücretleri ile ekstra maliyete neden olsa da, gerçek zamanlı müdahalenin yapılabilmesi ve referans cihaz ile koordine edilmesini kolaylaştırmaktadır. Mikrodenetleyiciler, genellikle Wi-Fi modülü ile IoT sistemine bağlanabilmektedir. Bu işlem, aşağıdaki adımları içermektedir.


1. Mikrodenetleyicinin Wi-Fi modülünün gerekli yazılımın yüklenmesi: Mikrodenetleyicinin Wi-Fi modülünü kullanmasına izin verecek olan yazılım paketidir.
2. Wi-Fi modülünün konfigürasyonu: Bu adımda, mikrodenetleyici tarafından kullanılacak olan Wi-Fi ağının adı (SSID) ve şifresi gibi bilgiler girilir.
3. Bağlantı kurulması: Mikrodenetleyici Wi-Fi modülünü kullanarak IoT sistemi ile bağlantı kurar. Mikrodenetleyicinin IoT sistemi tarafından sağlanan IP adresi veya DNS adı gibi bilgileri kullanarak gerçekleştirilir.
4. Veri aktarımı: Bağlantı kurulduktan sonra, mikrodenetleyici, sensörler ve diğer cihazlar tarafından toplanan verileri IoT sistemi ile paylaşabilir. Bu veriler, genellikle HTTP veya MQTT gibi bir protokol kullanarak gönderilir.

Referans cihaz olarak kullanılan Thermo Scientific pDR-1500, iç ve dış ortamlarda havadaki toz, duman ve sislerin solunabilir fraksiyonunun ölçümü için ışık saçılımı algılama konfigürasyonu optimize edilmiş, oldukça hassas bir nefelometrik (yani fotometrik) monitördür. pDR-1500, yüksek RH yüzdesine sahip ortamlarda bile ölçüm hatalarını azaltmak için bir sıcaklık ve bağıl nem (RH) sensörü içerir. Ek olarak, akış kontrolü hacimseldir ve yerleşik barometrik basınç sensörü, sıcaklık sensörü ve

hassas bir orifis boyunca kalibre edilmiş diferansiyel basıncın dijital geri bildirim yoluyla korunur. Hacimsel akış debisinin ayarlanması ile iki tip başlık kullanılarak istenilen partikül madde boyut fraksiyonu ölçümleri vermektedir.

2.2. Veri Analizi

Sensörlerden alınan ham verilerin toplanmasından, kullanılan nihai regresyon modeline kadar izlenen akış şeması Şekil 3'te verilmiştir.



Şekil 3. Model kullanımı için akış şeması.

Sensörlerden toplanan ham verilerin doğruluğunun belirlenmesi amacı ile aykırı değerlerden temizlenmiştir. Partikül madde dışında diğer değişkenler belirlenerek bunlar arasındaki ilişkiler değerlendirilmiştir. Partikül maddeye ek olarak sıcaklık, bağıl nem, çığ noktası ve referans cihazdan ölçülen basınç değeri ile toplam 10 değişken seçilmiştir. İstatistiksel değerlendirmeler yapılarak korelasyon analizleri gerçekleştirilmiştir. Veri setinin %20'si test için geri kalan %80'i ise eğitim için kullanılmıştır. Modelin performansı test verileri üzerinden değerlendirilmiş ve hiperparametreler ayarlanarak optimizasyon işlemi yapılmıştır. RF için çalışılan hiperparametreler; ağaç sayısı, ağacın maksimum derinliği, ağacın dallanması ile ilgili optimal değerlerin bulunması ile gerçekleştirilirken, SVR için toleransın ve kernel fonksiyonunun parametresini belirleyen optimal değerler olarak kullanılmıştır. İstatistiksel göstergeler; RMSE, ortalama mutlak hata (MAE) ve R^2 değerleri kullanılarak en uygun regresyon modeli seçilmiştir. Tüm analizlerde R versiyon 4.2.1 ("Funny-Looking Kid") kullanılmıştır.

2.2. Regresyon Modelleri

Kullanılan regresyon modelleri çok değişkenli doğrusal regresyon (ÇDR), RF (Random Forest - Rastgele orman) ve SVR (Supply Vector Regression-Destek Vektör Regresyonu) modelleridir. Çok değişkenli doğrusal regresyon, birden çok bağımsız değişken (öngörücü veya açıklayıcı değişkenler olarak da bilinir) ile tek bir bağımlı değişken (tepki veya sonuç değişkeni olarak da bilinir) arasındaki ilişkiyi modellemek için kullanılan istatistiksel bir tekniktir. Yalnızca bir bağımsız değişken içeren basit doğrusal regresyonun (BDR) bir uzantısıdır.

Çok değişkenli doğrusal regresyon denkleminin temel formu Eşitlik-1'de gösterilmiştir.

$$Y = B_0 + B_1X_1 + B_2X_2 + \dots + B_nX_n \quad (1)$$

Burada; Y: bağımlı değişken, B_0 : sabit(veya kesişme noktası, B_1, B_2, \dots, B_n ; her bir bağımsız değişken (X_1, X_2, \dots, X_n) için katsayılarıdır. Çok değişkenli doğrusal regresyonun amacı verilere en uygun katsayıların ($B_0, B_1, B_2, \dots, B_n$) değerlerini tahmin etmektir. Katsayılar tahmin edildikten sonra model, bağımsız değişkenlerin yeni değerleri verildiğinde bağımlı değişkenin değeri hakkında tahminlerde bulunmak için kullanılmıştır.

Rastgele karar ormanı regresyonu, karar ağaçlarının oluşturulması için rastgele seçilen örnekler ve rastgele seçilen değişkenler kullanır [40]. Bu, her karar ağacının farklı bir yapıda olmasını ve farklı değişkenleri kullanmasını sağlar. Bu sayede, ağaçlar arasındaki varyasyon artar ve overfitting riski azaltılır. Ayrıca, her karar ağacının sadece belirli bir kısmı veri kümesiyle eğitilmesi, modelin genel performansını artırır. Rastgele orman regresyonunda, nihai tahmin, çoklu karar ağaçlarının tahminlerinin ortalaması alınarak yapılır. Her karar ağacı, verilerin rastgele bir alt kümesinde ve özelliklerin rastgele bir alt kümesinde eğitilir.

Rastgele karar orman regresyonunun son tahmini Eşitlik-2 ile temsil edilebilir:

$$Tahmin = \frac{1}{n} * \sum(\text{Her ağacın tahmini}) \quad (2)$$

Burada; n: ormandaki ağaç sayısı, Σ :toplama operatörüdür. Her ağacın tahmini, ormandaki her karar ağacı tarafından yapılan tahmindir.

Destek vektör makinası (SVM) regresyonu (SVR), denetimli öğrenim algoritmasıdır ve hem sınıflandırma hem de regresyon için kullanılabilir [41,42]. SVM regresyonun amacı, veri noktalarını farklı sınıflara ayırmak için yüksek boyutsal özellik uzayında bir doğrusal sınır belirlemektir. SVR'nin temel fikri, veri noktalarını iki sınıfa ayırmak için bir doğrusal sınır kullanmaktır. Birinci sınıf, sınırdan belirli bir mesafede olan veri noktalarıdır ("epsilon-tube"), diğer sınıf ise bu mesafenin dışındaki veri noktalarıdır. Mesafe, epsilon olarak adlandırılan bir hiperparametre tarafından kontrol edilir. SVR denklemi Eşitlik-3'teki gibi verilmektedir.

$$y = wx + b \quad (3)$$

Burada, y:tahmin edilen değer, w:ağırlık vektörü lineer sınırın katsayıları, x:özelliklerin girdi vektörü ve b: bias terimidir. SVR regresyonunun amacı, w ve b'nin optimal değerlerini bulmaktır ve bu değerler en büyük ayrımı sağlar. Bu ayrım sınır ve veri noktaları arasındaki mesafedir.

$$\text{minimize} \quad \frac{1}{2} \|w\|^2 \quad (4)$$

$$\text{koşul} \rightarrow |y(i) - (wx(i) + b)| \leq \text{epsilon}, i = 1, 2, 3, \dots, n \quad (5)$$

Burada, i:veri noktasının indeksi, n: veri noktalarının sayısı, y(i): i'deki veri noktasının gerçek değeri, x(i): i'deki veri noktasının özellik vektörüdür. Optimizasyon probleminin çözümü w ve b'nin optimal değerlerini verir ve bu değerler yeni veri noktaları için tahmin yapmak için kullanılmıştır.

3. BULGULAR VE TARTIŞMA

Kalibrasyon çalışmaları üç sensör ve üç referans cihaz ile gerçekleştirilmiştir. Çalışmada kullanılan sensörler; S1, S2 ve S3 olarak, referans cihazlar ise R1, R2 ve R3 olarak verilmiştir. OPC ve referans cihazdan gerçek zamanlı dakikalık veriler ortalama saatlik verilere çevrilerek iki ay boyunca toplanmıştır. İlk ay boyunca sensörler ile referans cihazlarının ürettiği verilerin değerlendirilmesi yapılarak, birbirlerine göre korelasyonları incelenmiştir. Tanımlayıcı istatistikler Tablo 1'de ve korelasyon matrisi ise Tablo 2'de verilmiştir.

Tablo 1. Sensör ve referans cihazlarının tanımlayıcı istatistikleri.

	S1	S2	S3	R1	R2	R3
Ortalama ($\mu\text{g}/\text{m}^3$)	3,53	2,91	15,5	8,86	8,44	8,95
Medyan ($\mu\text{g}/\text{m}^3$)	3,33	2,56	3,57	8,19	7,61	8,15
Standart Sapma ($\mu\text{g}/\text{m}^3$)	1,58	1,47	11,2	4,23	4,13	4,22
Shapiro-Wilk W	0,88	0,85	0,47	0,90	0,88	0,89
Shapiro-Wilk p	<,001	<,001	<,001	<,001	<,001	<,001

Tablo 2. Sensör ve referans cihazları Pearson's r korelasyon matrisi.


	S1	S2	S3	R1	R2	R3
S1	—					
S2	0,472	—				
S3	0,269	0,293	—			
R1	0,517	0,713	0,454	—		
R2	0,538	0,658	0,473	0,975	—	
R3	0,562	0,710	0,572	0,989	0,965	—

Pearson r korelasyon yaklaşımına göre, tüm sensörler arasında anlamlı bir korelasyon vardır ($p < ,001$). S2 ve S1, S3'e göre daha fazla ilişim gösterdiği belirlenmiştir. Referans cihazları kendi aralarında ve sensörler ile anlamlı bir korelasyon gösterirken, S3 cihazı nispeten daha düşük ilişim göstermektedir. Fakat bu istatistiksel yaklaşım her ne kadar sensör ve referans cihazların koordineli çalıştığı gösterse de, verilerin doğrusallığını tespit etmek ve referans cihazın ürettiği verilere yakınsamalarını sağlamak gereklidir. Sensör verilerinin doğrusallığı BDR modeli ile belirlenebilir. Bu aşamadan sonraki analizler için üç referans cihazın ortalama değerleri kullanılmıştır. Tablo 3, doğrusallığı incelemek için kullanılan BDR modelinin sonuçlarını özetlemektedir.

Tablo 3. Referans cihaz ve üç sensörün BDR modeli sonuçları.

	Model	Eğim (a)	Kayım (b)	R ²	RMSE	MAE
S1	$PM_{1, referans} = PM_1 * a + b$	1,26	4,42	0,22	3,72	2,75
S2		2,14	2,20	0,54	2,78	2,18
S3		0,15	8,12	0,20	3,75	2,69

Referans cihazların saatlik ortalama PM₁ verisine göre sensörlerin ürettiği saatlik ortalama PM₁ verileri kullanılarak kurulan modellerde, eğim, kayım, RMSE ve MAE değerlendirilmiştir. BDR modellemesi sonuçlarına göre, R² değeri göz önüne alındığında, S1 ile kabul edilebilir [39] değere sahip olmasına rağmen diğer iki sensör aynı durumu sağlamaktan uzaktır. Bunun olası nedeni OPC'ler üzerinde bağıl nemin (>%70) doğrusal olmayan önemli bir etkisi olmasıdır [43]. Aynı zamanda, sıcaklık, çığ noktası gibi diğer parametrelerin, referans cihazla birlikte kalibre edilmesi gereklidir. BDR modeli bu durumun değerlendirilmesi için yetersiz kaldığından, çok değişkenli doğrusal regresyon (ÇDR) modeli uygulanmıştır. Bu durumu değerlendirmek için sensörler üzerinde yapılan ÇDR analizinde değişkenlerin katkısı incelenmiştir. Referans cihazların da ölçüm yaptığı değişkenler (sıcaklık, nem ve basınç) dahil edilmiş ve sensörlerin verdiği tüm değişkenler (PM₁, PM_{2.5}, PM₁₀, sıcaklık, nem) ile sıcaklık ve nem değişkenine bağlı çığ noktasının (dew point) katkısı incelenmiştir. Higroskopik özelliklerini yansıtan yüksek bağıl nem koşulları altında su alımı nedeniyle parçacık boyutlarındaki değişiklikleri düzeltmek için algoritmalar kurulmuştur [44]. Önceki araştırmalarda çığ noktasını partikül maddelerin higroskopik büyümesinin iyi bir temsilcisi olduğunu göstermiştir [45,46]. Diğer partikül madde fraksiyonlarının hesaplamaya katılmasının nedeni OPC çalışma prensibinin 16 farklı kategoride boyutlarına göre partikül maddeyi sınıflandırmasıdır [47]. ÇDR analizi için eğitim/test validasyonu kullanılarak verilerin %20'si rastgele test için ayrılmıştır. ÇDR analizi sonuçlarına göre test veri setinde en düşük RMSE değerine sahip olan S2 sensörünün ve R² değeri ise 0,59 olarak bulunmuştur. Şekil 5'te referans cihazı ile S2 test veri setindeki grafiği verilmiştir.



Şekil 4. Test verileri için referans cihaz ve S2 sensörünün ÇDR modeli tahminin uyumluluğu.


Gözlem sayısı 318 olan test verilerinde medyan değerleri referans cihaz ve sensör için sırasıyla 8.52 ve 8.29 $\mu\text{g}/\text{m}^3$ olarak bulunmuştur. BDR modeli referans cihaz ile sensör verilerinin arasındaki etkileşimi ve diğer değişkenlerin katkısını anlamaya yardımcı olsa da sensörlerin referans cihaz ile her gözlem için yakın değerler vermesi için çalışmalar devam etmiştir. Regresyon modellerinin makina öğrenmesinde kullanıldığı bazı algoritmalar ile on değişkenin üzerinden referans cihaz ve sensör arasındaki yakınsaklık incelenmiştir. Kalibrasyon çalışmalarına destek vektör regresyonu ve rastgele karar ormanları regresyonu eklenmiştir. Modeller, en fazla uyum sağlayan hiperparametrelerin belirlenmesi ile valide edilmiştir. Kullanılan tüm modeller için istatistiksel veriler Tablo 4'te yer almaktadır.

Tablo 4. Uygulanan modellerden elde edilen istatistiksel göstergeler.

	RF			SVR			ÇDR		
	R ²	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE
S1	0,85	1,41	1,11	0,86	1,39	1,03	0,38	3,2	2,1
S2	0,90	1,29	0,93	0,93	1,11	0,7	0,59	2,67	2,08
S3	0,93	1,33	1,02	0,86	1,68	1,14	0,62	2,77	2,06

Tüm modeller için anlamlılık düzeyi 0,05 olarak ayarlanmıştır. Model sonuçlarına göre ÇDR modelinin görece yüksek RMSE ve MAE değerine sahip olması nedeniyle sensör performansı için yapılacak iyileştirme çalışmalarında, makina öğrenmesi modellerine göre daha zayıf olduğu görülmektedir. Makina öğrenmesi modellerine cihazlar tarafından verilen tepkiler değişiklik göstermektedir. Cihazlar için oluşturulan modelde hesaplanan MAE ve RMSE değerleri birbirine yakınlık gösterse de, S2 cihazının modellerle birlikte veri üretim performansının diğer cihazlara göre daha iyi olduğu görülmektedir. Üç cihaz için ortalama olarak incelendiğinde RF modeli ile kurulan modelin diğer iki modele göre daha yakınsak sonuçlar verdiği görülmektedir. SVR ve RF modelleri, ÇDR'ye göre veri kalitesini yükseltmede daha başarılı sonuç vermişlerdir. ÇDR modelinde hesaplanan RMSE değerine göre, üç cihaz için SVR modelinin $51,7 \pm 10,1\%$, RF modelinin ise $53,3 \pm 2,4\%$ oranında veri üretim performansını artırdığı hesaplanmıştır. Literatürde, OPC'lerin PM₁ verisi üretim performansını iyileştirildiği makina öğrenmesinin kullanılmadığı bir çalışmada, test verileri için bu oranın $25 \pm 1\%$

artırıldığı görülmüştür [32]. Makina öğrenmesinin OPC veri kalitesini artırmayı amaçladığı bir diğer çalışmada ise SVR dışında farklı iki makina öğrenmesi modeli kullanılmıştır. Üç farklı OPS cihazının farklı modeller ile farklı iyileştirme sonuçları verdiği tespit edilmiştir. Örnek olarak verilen test PM₁ verileri için R² en fazla 0,857 değerine ulaşırken, SVR modelinin R² değeri 0,841 olarak verilmiştir [19]. Çalışmada, az sayıda örneklem sayısının “overfitting” (aşırı öğrenme) durumunu azaltmasına rağmen örneklem sayısının artırılması gerekliliği vurgulanmıştır. Test verileri ile iki makina öğrenmesi modelinin referans cihazla uyumlu bir şekilde veri üretmesi, S2 cihazı için Şekil 5’de grafikleştirilmiştir. Toplam 318 gözlem sayısı ile yapılan test verilerinin iki regresyon modelinin çıktıları, referans cihaz ile uyum içindedir. Daha fazla örneklem sayısı ile daha fazla saha çalışması yapılarak ve farklı hiperparametre değerleri ve farklı makina öğrenmesi modelleri kullanılarak, düşük maliyetli partikül madde sensörlerinin veri üretim performansının iyileşeceği açıktır.



Şekil 5. S2 ve referans cihaz için rastgele karar ormanı ve destek vektör regresyonu modelleri ile test verilerinin uyumluluğu.

SONUÇ

Optik partikül sayıcılar ve referans cihazlar ile üretilen PM₁ ham veri değerleri farklılık göstermektedir. Değişen zaman aralıklarında çevresel parametrelere karşı hassasiyet göstermektedirler. OPC’lerden gelecek ham veriler ile saha çalışmalarının yapılması, gerçeğe aykırı sonuçların üretilmesine neden olabilir. Yine de, referans cihazlarla anlamlı ilişim göstermeleri, bu cihazların belirli katsayılar veya modellerle gerçeğe yakın sonuçlar verebileceğine işaret etmektedir. Sadece PM değerine bağlı doğrusal model ile belirlenen katsayı, referans cihazla doğrusal bir veri üretmediği görülmüştür. Modele dahil edilen çevresel etmenler ile gerçekleştirilen basit doğrusal model, bulguların istenilen performans ile gerçek verilere yakınsamadığını göstermiştir. Aynı zamanda, bu modellerin aşırı uyum gibi modellemede istenmeyen durumlara yol açabilmesi söz konusudur. Bu nedenle, makina öğrenmesi algoritmaları kullanan model regresyonları, kalibrasyon çalışmalarına dahil edilmiştir. Kullanılan iki modelin, referans cihazlardan üretilen ham veriler ile benzer sonuç tahminlerine ulaştığı görülmüştür. Fakat, bulunan değerlerin OPC’lerden çıkan sonuçlara göre referans cihazı baz alarak tahmin edildiği değerler olduğu göz önünde bulundurulmalıdır. Kalibrasyon çalışmalarının farklı

aralıklarla yapılması, cihazların nispeten kısa ömürlü elektronik parçaları kaynaklı hataları düzeltmek için gerekli olacağı düşünülmektedir. Ayrıca, örneklem sayısının büyüklüğü ile modellerin başarısı artırılabilir. En uygun hiperparametre değerlerinin modellere dahil edilmesi düşük maliyetli partikül madde sensörlerinin doğruluğunu ve kesinliğini artıracığından şüphe yoktur. Son dönemde çalışmalara konu olan yeni nesil makina öğrenmesi algoritmalarının da yakın gelecekte kalibrasyon çalışmalarına dahil olacağı düşünüldüğünde, iç hava partikül madde kirliliğinin her noktada kesinlik ve doğruluk içererek belirlenmesi, iç ortam havalandırma ve şartlandırma tasarımlarında yeni bir paradigmanın oluşmasına neden olabilir. İnsan sağlığı ve enerji tasarrufu çalışmalarına katkı sağlayabilecek bu denli çalışmalar ve yatırımların, iç ortamlarda daha fazla zaman geçiren insanların ve sürekli tükenen kaynaklarımızın korunmasında başrol oyuncusu olabilecek gelişmeleri beraberinde getirmesi kuvvetle muhtemel görülmektedir.

TEŞEKKÜRLER

Bu çalışma TÜBİTAK (120R040) ve İYTE BAP (2022İYTE-1-0007) tarafından desteklenmiştir.

KAYNAKLAR

- [1] COHEN, A. J., BRAUER, M., BURNETT, R., ANDERSON,, ve FOROUZANFAR, M. H., "Estimates and 25-year trends of the global burden of disease attributable to ambient air pollution: an analysis of data from the Global Burden of Diseases Study 2015", *The Lancet* 389.10082, ss. 1907-1918, 2017.
- [2] BRAUER, M., FREEDMAN, G., FROSTAD, J., Van DONKELAAR,, ve COHEN, A., "Ambient Air Pollution Exposure Estimation for the Global Burden of Disease 2013", *Environ. Sci. Technol.*, 50.1, ss. 79-88, 2016.
- [3] KIM, K.-H., KABIR, E., ve KABIR, S., "A review on the human health impact of airborne particulate matter", *Environ. Int.*, 74, ss. 136–143, 2015.
- [4] DSÖ, (Dünya Sağlık Örgütü), Household air pollution attributable deaths [26-08-2022 tarihinde erişildi]. Online: <https://www.who.int/data/gho/data/indicators/indicator-details/GHO/household-air-pollution-attributable-deaths>, 2019.
- [5] WANG, X., XU, Z., SU, H., HO, H. C.,....., ve CHENG, J., "Ambient particulate matter (PM1, PM2.5, PM10) and childhood pneumonia: The smaller particle, the greater short-term impact?", *Sci. Total Environ.*, 772, s. 145509, 2021.
- [6] YIN, P., GUO, J., WANG, L., FAN, W.,....., ve DONG, Z., "Higher Risk of Cardiovascular Disease Associated with Smaller Size-Fractioned Particulate Matter", *Environ. Sci. Technol. Lett.*, 7.2, ss. 95-101, 2020.
- [7] ZHANG, Y., DING, Z., XIANG, Q., WANG,, ve MAO, F., "Short-term effects of ambient PM1 and PM2.5 air pollution on hospital admission for respiratory diseases: Case-crossover evidence from Shenzhen, China", *Int. J. Hyg. Environ. Health.*, 224, s. 113418, 2020.
- [8] MENG, Q., ZHANG, J., KANG, J., ve WU, Y., "Effects of sound environment on the sleep of college students in China", *Sci. Total Environ.*, 705, s. 135794., 2020.
- [9] KAUR, S., NIEUWENHUIJSEN, M. J., ve COLVILE, R. N., "Fine particulate matter and carbon monoxide exposure concentrations in urban street transport microenvironments", *Atmos. Environ.*, 41(23), ss. 4781-4810, 2007.
- [10] Van den BOSSCHE, J., PETERS, J., VERWAEREN, J., BOTTELDOOREN, D.,, ve De BAETS, B., "Mobile monitoring for mapping spatial variation in urban air quality: Development and validation of a methodology based on an extensive dataset", *Atmos. Environ.*, 105, ss. 148-161, 2015.
- [11] HEIMANN, I., BRIGHT, V. B., MCLEOD, M. W., MEAD, M. I.,....., ve JONES, R. L., "Source attribution of air pollution by spatial scale separation using high spatial density networks of low cost air quality sensors", *Atmos. Environ.*, 113, ss. 10-19, 2015.

- [12] BORREGO, C., COSTA, A. M., GINJA, J., AMORIM, M.,..., ve De VITO, S., “Assessment of air quality microsensors versus reference methods: The EuNetAir joint exercise”, *Atmos. Environ.*, 147, ss. 246–263., 2016.
- [13] deSOUZA, P., KAHN, R., STOCKMAN, T., OBERMANN, W., ..., ve KINNEY, P., “Calibrating Networks of Low-Cost Air Quality Sensors”, *Atmos. Meas. Tech. Discuss.*, 2022(March), ss. 1–34., 2022.
- [14] LEWIS, A. C., LEE, J. D., EDWARDS, P. M., SHAW, M. D., ..., ve GILLOT, S. R., “Evaluating the performance of low cost chemical sensors for air pollution research”, *Faraday Discuss.*, 189, ss. 85–103., 2016.
- [15] RAI, A. C., KUMAR, P., PILLA, F., SKOULOUDİS, A. N., ..., ve RICKERBY, D., “End-user perspective of low-cost sensors for outdoor air pollution monitoring”, *Sci. Total Environ.*, 607, ss. 691–705., 2017.
- [16] SNYDER, E. G., WATKINS, T. H., SOLOMON, P. A., THOMA, E. D., ..., ve PREUSS, P. W., “The changing paradigm of air pollution monitoring”, *Environ. Sci. Technol.*, 47(20), ss. 11369–11377., 2013.
- [17] BUČAR, K., MALET, J., STABILE, L., PRAŽNIKAR, ..., ve ŽITNIK, M., “Statistics of a sharp gp2y low-cost aerosol pm sensor output signals”, *Sensors (Switzerland)*, 20(23), s. 6707, 2020.
- [18] WILLIAMS, R., KILARU, V. J., SNYDER, E. G., KAUFMAN, A., ..., ve HAFNER, H., , “Air Sensor Guidebook”., US Environmental Protection Agency, 2014.
- [19] CHOJER, H., BRANCO, P., MARTİNS, F. G., ALVIM-FERRAZ, M. C. M., ve SOUSA, S. I. V., “Can data reliability of low-cost sensor devices for indoor air particulate matter monitoring be improved?—An approach using machine learning”, *Atmos. Environ.*, 286, s. 119251., 2022.
- [20] MORAWSKA, L., THAI, P. K., LIU, X., ASUMADU-SAKYI, A., ..., ve WILLIAMS, R., “Applications of low-cost sensing technologies for air quality monitoring and exposure assessment: How far have they gone?”, *Environ. Int.*, 116, s. 286-299, 2018.
- [21] HAGAN, D. H., ve KROLL, J. H., “Assessing the accuracy of low-cost optical particle sensors using a physics-based approach”, *Atmos. Meas. Tech.*, 13(11), ss. 6343-6355, 2020.
- [22] KUMAR, P., MORAWSKA, L., MARTANI, C., BISKOS, G., ..., ve BRITTER, R., , “The rise of low-cost sensing for managing air pollution in cities”, *Environ. Int.*, 75, ss. 199–205., 2015.
- [23] MUELLER, M., MEYER, J., ve HUEGLIN, C., “Design of an ozone and nitrogen dioxide sensor unit and its long-term operation within a sensor network in the city of Zurich”, *Atmos. Meas. Tech.*, 10(10), ss. 3783–3799., 2017.
- [24] POPOOLA, O. A. M., STEWART, G. B., MEAD, M. I., ve JONES, R. L., “Development of a baseline-temperature correction methodology for electrochemical sensors and its implications for long-term stability”, *Atmos. Environ.*, 147, ss. 330–343., 2016.
- [25] MEAD, M. I., POPOOLA, O. A. M., STEWART, G. B., LANDSHOFF, P., ..., ve DİCKS, J., “The use of electrochemical sensors for monitoring urban air quality in low-cost, high-density networks”, *Atmos. Environ.*, 70, ss. 186–203., 2013.
- [26] CASTELLINI, S., MORONI, B., ve CAPPELLETTI, D., “PMetro: Measurement of urban aerosols on a mobile platform”, *Measurement*, 49, ss. 99–106., 2014.
- [27] SOUSAN, S., KOEHLER, K., HALLETT, L., ve PETERS, T. M., “Evaluation of the Alphasense optical particle counter (OPC-N2) and the Grimm portable aerosol spectrometer (PAS-1.108)”, *Aerosol Sci. Technol.*, 50(12), ss. 1352–1365., 2016.
- [28] VIANA, M., RIVAS, I., RECHE, C., FONSECA, A. S., ..., ve SUNYER, J., “Field comparison of portable and stationary instruments for outdoor urban air exposure assessments”, *Atmos. Environ.*, 123, ss. 220–228., 2015.
- [29] MANIKONDA, A., ŽÍKOVÁ, N., HOPKE, P. K., ve FERRO, A. R., “Laboratory assessment of low-cost PM monitors”, *J. Aerosol Sci.*, 102, ss. 29–40., 2016.
- [30] STEINLE, S., REIS, S., SABEL, C. E., SEMPLE, S., ..., ve LIN, C., “Personal exposure monitoring of PM_{2.5} in indoor and outdoor microenvironments”, *Sci. Total Environ.*, 508, ss. 383–394., 2015.
- [31] GAO, M., CAO, J., ve SETO, E., “A distributed network of low-cost continuous reading sensors to measure spatiotemporal variations of PM_{2.5} in Xi’an, China”, *Environ. Pollut.*, 199, ss. 56–65., 2015.
- [32] KOSMOPOULOS, G., SALAMALIKIS, V., PANDIS, S. N., YANNOPOULOS, ..., ve KAZANTZIDIS, A., “Low-cost sensors for measuring airborne particulate matter: Field evaluation and calibration at a South-Eastern European site”, *Sci. Total Environ.*, 748, s. 141396, 2020.

- [33] CARRICO, C. M., BERGIN, M. H., XU, J., BAUMANN, K., ve MARING, H., “Urban aerosol radiative properties: Measurements during the 1999 Atlanta supersite experiment”, *J. Geophys. Res. Atmos.*, 108(7), 2003.
- [34] DUBEY, R., PATRA, A. K., JOSHI, J., BLANKENBERG, ..., ve RAVAL, S., “Evaluation of low-cost particulate matter sensors OPC N2 and PM Nova for aerosol monitoring”, *Atmos. Pollut. Res.*, 13(3), s. 101335., 2022.
- [35] HOLSTIUS, D. M., PILLARISSETTI, A., SMITH, K. R., ve SETO, E., “Field calibrations of a low-cost aerosol sensor at a regulatory monitoring site in California”, *Atmos. Meas. Tech.*, 7(4), ss. 1121–1131., 2014.
- [36] LE, T. C., SHUKLA, K. K., CHEN, Y. T., CHANG, S. C.,, ve TSAI, C. J., , “On the concentration differences between PM_{2.5} FEM monitors and FRM samplers”, *Atmos. Environ.*, 222, s. 117138, 2020.
- [37] NGUYEN, N. H., NGUYEN, H. X., LE, T. T. B., ve VU, C. D., “Evaluating Low-Cost Commercially Available Sensors for Air Quality Monitoring and Application of Sensor Calibration Methods for Improving Accuracy”, *Open J. Air Pollut.*, 10(01), ss. 1–17, 2021.
- [38] WANG, Y., DU, Y., WANG, J., ve LI, T., “Calibration of a low-cost PM_{2.5} monitor using a random forest model”, *Environ. Int.*, 133, s. 105161, 2019.
- [39] DUVALL, R., CLEMENTS, A., HAGLER, G., KAMAL, A.,, ve GREENE, D., “Performance Testing Protocols, Metrics, and Target Values for Fine Particulate Matter Air Sensors: Use in Ambient, Outdoor, Fixed Sites, Non-Regulatory Supplemental and Informational Monitoring Applications”, *US EPA Off. Res. Dev.*, 2021.
- [40] BIAU, G., ve SCORNET, E., “A random forest guided tour”, *Test*, 25(2), ss. 197–227, 2016.
- [41] NOBLE, W. S., “What is a support vector machine?”, *Nat. Biotechnol.*, 24(12), ss. 1565–1567, 2006.
- [42] WANG, L., *Support vector machines: theory and applications*, Vol. 177. Springer Science & Business Media, 2005.
- [43] ZHENG, T., BERGIN, M. H., JOHNSON, K. K., TRIPATHI, S. N.,, ve CARLSON, D. E., “Field evaluation of low-cost particulate matter sensors in high-and low-concentration environments”, *Atmos. Meas. Tech.*, 11(8), ss. 4823–4846, 2018.
- [44] Di ANTONIO, A., POPOOLA, O. A. M., OUYANG, B., SAFFELL, J., ve JONES, R. L., “Developing a relative humidity correction for low-cost sensors measuring ambient particulate matter”, *Sensors*, 18(9), s. 2790, 2018.
- [45] CLEMENTS, A. L., GRISWOLD, W. G., Rs, A., JOHNSTON, J. E., HERTING, M. M.,, ve HANNİGAN, M., “Low-cost air quality monitoring tools: from research to practice (a workshop summary)”, *Sensors*, 17(11), s. 2478, 2017.
- [46] MALINGS, C., TANZER, R., HAURYLIUK, A., SAHA, P. K.,, ve SUBRAMANIAN, R., “Fine particle mass monitoring with low-cost sensors: Corrections and long-term performance evaluation”, *Aerosol Sci. Technol.*, 54(2), ss. 160–174, 2020.
- [47] CRILLEY, L. R., SHAW, M., POUND, R., KRAMER, L. J.,, ve POPE, F. D., “Evaluation of a low-cost optical particle counter (Alphasense OPC-N2) for ambient air monitoring”, *Atmos. Meas. Tech.*, 11(2), ss. 709–720, 2018.

ÖZGEÇMİŞ

Çağrı ŞAHİN

1988 yılı İstanbul doğumludur. 2013 yılında İTÜ Kimya Bölümünü bitirmiştir. 2017 yılında aynı üniversitenin Çevre Mühendisliği, Bilimi ve Teknolojileri Bölümünde Yüksek Lisansını tamamlamıştır. 2017 yılında aynı bölümün doktora programına başlamıştır. 2018 yılında İYTE Çevre Mühendisliği Bölümünde araştırma görevlisi olarak görev yapmaya başlamıştır. Aynı yıl İYTE Çevre Mühendisliği Doktora Programına geçiş yapmıştır. Günümüzde doktora eğitimi devam etmektedir. Doktora tezinin konusu iç hava kalitesi ve kontrolü çalışmalarından oluşmaktadır.



Sait Cemil SOFUOĞLU

DEÜ Mühendislik Fakültesi Çevre Mühendisliği Bölümü'den mezun oldu. İTÜ Çevre Mühendisliği Bölümünde Araştırma Görevlisi olarak iki yıl çalıştı. Öğrenimine ABD'de devam edip yüksek lisans ve doktorasını Illinois Institute of Technology'den aldı. Halen, İYTE Çevre Mühendisliği bölümünde Prof.Dr. unvanı ile çalışmakta, iç hava kirliliği, hava kirliliği ve maruziyet – risk değerlendirmesi konularında araştırmalar yapmakta ve dersler vermektedir.