



Kampüs İçi Kapalı Alanlarda Hava Kalitesinin Modellenmesi ve Karar Destek Sistemi Geliştirilmesi

Elif Cesur^{1*}, Cemal Efe²

¹ İstanbul Medeniyet Üniversitesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye

² İstanbul Medeniyet Üniversitesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye

elif.karakaya@medeniyet.edu.tr, cemal_efe2000@hotmail.com

Öz

Zeki Kampüs kapsamı içerisinde üniversite kampüslerinin kapalı alanlarında hava kalitesinin tahmin edilmesi, virüs bulaş riskini en aza indirilmesi açısından çok önemlidir. Buna bağlı olarak sınıflarda, idari ofislerde ve toplantı salonlarında hava ölçümlerinin kontrol limitleri dışına çıkması durumunda uyarılar vererek kararlar almasını sağlayacak bir karar destek sisteminin kurulması, bu riski kontrol altında tutmayı sağlayabilecektir. Bu çalışmada öncelikle karbondioksit, sıcaklık, nem, basınç ve hava kalitesi (MQ135) sensörleri insan giriş ve çıkışının yoğun olduğu bir sınıfa kurulmuş ve düzenli olarak veri alınması sağlanmıştır. Çalışmanın ikinci aşamasında veri madenciliği teknikleri ile bu sensör verilerinin veri ön işleme teknikleri ile analizleri yapılmıştır. Çalışmanın ana amacı yapay sinir ağları, karar ağacı ve destek vektör makine teknikleri ile sensör verilerinin modellenmesi ve kişi sayısı artışı, cam veya kapının açılması, ve ders arası süresinin uzatılması gibi nedenlerden kaynaklı olarak havada gerçekleşen ani değişikliklerin model tarafından yakalanmasını sağlamaktır. Çalışmanın sonucu, kabul edilebilir aralıkların dışına çıkan hava kalitesi durumlarının tespiti sonucunda odanın ne zaman havalandırılacağına karar vermektir. Bu çalışmada kurduğumuz modeller kampüs dışında da örneğin toplu taşıma araçlarının, işyerlerinin, ofislerin, restoranların, kafelerin ve özel araçların havalandırma sistemlerinde kullanılabilir özelliktedir.

Anahtar Kelimeler: Makine Öğrenmesi, Zeki Kampüs, Karar Destek Sistemleri

Modeling of Indoor Air Quality in Campus and Developing a Decision Support System

Abstract

Estimating the air quality in the indoor areas of university campuses within the scope of Intelligent Campus is very important in terms of minimizing the risk of virus transmission. In order to reduce this threat, it will be possible to develop a decision support system that will allow it to make decisions by issuing alerts in the event that air measurements exceed the control limits in the classrooms, executive offices, and meeting rooms. In this investigation, carbon dioxide, temperature, humidity, pressure, and air quality (MQ135) sensors were first installed in a classroom where there was a significant amount of human input and output, and regular data were collected. In the second stage of the study, data mining techniques and data preprocessing techniques were used to analyze these sensor data. The main purpose of the study is to model sensor data with artificial neural networks, decision tree and support vector machine techniques, and to ensure that sudden changes in the air due to reasons such as increasing the number of people, opening the window or door, and extending the time between classes are captured by the model. The result of the study is to decide when to ventilate the room as a result of the detection of air quality conditions that fall outside the acceptable ranges.

Keywords: Machine Learning Algorithms, Intelligent Campus, Decision Support Systems

* Sorumlu yazar
E-posta adresi: elif.karakaya@medeniyet.edu.tr

Alındı : 21 Aralık 2022
Revizyon : 14 Ocak 2023
Kabul : 7 Nisan 2023

1. Giriş (Introduction)

Massachusetts Teknoloji Enstitüsü'nde (MIT) yapılan bir araştırmada kapalı alanlarda sosyal mesafe kuralının virüs bulaşma riskini çok az etkilediği ve yetersiz kaldığı sonucuna ulaşılmıştır. Kapalı alanlarda sosyal mesafenin dışında ortamdaki insan sayısı, havalandırma seviyesi, maske takıp takmadıkları ve insanların ne yaptığı gibi değişkenler de çok önemli olduğu ortaya konulmuştur. İnsanların yemek yediği, konuştuğu, hapşırıldığı ve havanın hareket ettiği kapalı bir ortamlarda damlacıkların havada asılı durabildiği, daha boş ve sakin yerlerde ise bu parçacıkların yavaşça yere doğru hareket ettiği tespit edilmiştir. Bu nedenle araştırmacılar, virüs partiküllerinin havalandırma veya filtreleme yöntemiyle zararsız hale getirilebileceğini savunmaktadır. (Elibol, 2021).

Enfekte kişilerden saçılan küçük damlacıklar az miktarda virüs içermekte ve açık havada bu partiküller hızla buharlaşıp yok olmaktadır. Kapalı bir ortamın hava akımı ne kadar zayıf ve hacmi ne kadar küçük ise partiküllerin havada asılı kalma olasılığı da o aranda artmaktadır. Yapılan çalışmalar ve araştırmalar sosyal mesafe kuralının kapalı alanlarda virüsün bulaşmaması için yetersiz kaldığını göstermektedir. Bu sebeple kapalı ortamlarda mesafe yerine viral yük (kişi sayısı vb.) ve odanın hacmi ölçütleri bulaş riskinin azalması için önem kazanmaktadır. Enfekte bir kişinin de içerisinde bulunduğu toplu taşıma, hastane, okul, uçak veya bir otomobil gibi kapalı ortamlarda bulaş riskinin hesaplanabilmesi için yapılan çalışma veya simülasyonlarda 4 önemli korunma yöntemi belirlenmiştir. Bu korunma yöntemleri, 1) kapalı alanlarda insan yoğunluğunun azaltılması, 2) hasta ve duyarlı kişilerin birlikte maske kullanması, 3) semptomatik kişilerin izolasyonu ve 4) yeterli süre ve uygunlukta havalandırmanın yapılmasıdır. (Elibol, 2021) Yeni normale geçilmesiyle birlikte insanlar kapalı ortamlarda daha fazla vakit geçirmeye başlamıştır. Kış mevsiminde havanın soğumasıyla birlikte bu durum daha fazla artmaya başlamıştır. Üniversitelerin tekrardan yüz yüze eğitime başlamasıyla birlikte sınıflarda öğrenci ve öğretmenler risk altında kalmaktadır. Fakat sınıflardaki pencerelerin yetersizliği ve bazı sınıflarda havalandırmanın olmaması bulaşma riskini arttırmaktadır. Yüz yüze sınavlarda öğrenci sayısının artmasıyla birlikte dolaylı olarak hava kalitesi de azalmaktadır. Bu durum virüslerin bulaşıcılığını arttırmaktadır. Bu çalışmada, insanların bir arada bulunduğu yerlerden olan üniversite kampüslerinin kapalı alanlarında hava kalitesi tahmin modelleri ve karar destek sistemi geliştirilerek virüsün bulaşma riskini en aza indirilmesi amaçlanmıştır.

Öğrenci ve öğretmenlerin çoğunlukla bir arada bulunduğu kapalı kampüs ortamlarında hava kalitesi tahmin modelleri oluşturularak, hava kalitesinin düşmesi durumunda karar destek sistemi harekete geçerek kapalı ortamdaki hava kalitesi yükseltilmeye çalışılacaktır. Bu nedenle yaptığımız çalışmanın ileri

aşamalarında oluşturduğumuz model ve karar destek sistemleri ile entegre edilecek havalandırma sistemi hava kalitesinin düşmesi durumunda devreye girerek hava kalitesinin devamlı istenilen düzeyde kalmasını sağlayacaktır.

Kampüsteki kapalı alanlarda insan sayısının sabit olmaması ve devamlı değişmesi (sınıftaki öğrenci sayısı, idari ve derslik binalarına giren kişi sayısı, yemekhane ve kafeteryalardaki öğrenci sayısı vb.) hava kalitesinin de devamlı değişmesine neden olmaktadır. Makine öğrenmesi yöntemlerini kullanarak geliştirdiğimiz karar destek sistemi ile ortamdan elde edilen sıcaklık, nem, CO₂, partikül madde (PM₁₀) miktarı ve basınç verileri kullanılarak hava kalitesinin düşmesi durumunda havalandırma etkinleştirilecektir. Çalışmamızda kampüslerde kapalı ortamlardan elde edilen verilerin makine öğrenmesi algoritmaları ile modellenerek karar destek sistemi aracılığı ile havalandırma sisteminin daha etkin kullanımını ile hava kalitesinin sağlıklı düzeyde tutulması hedeflenmiştir. Ayrıca bu araştırmada kurduğumuz modeller kampüs dışında toplu taşıma araçları, iş yerleri, ofis, restoran, kafe, özel araçların havalandırma sistemlerinde de kullanılabilir olacaktır.

2. Literatür Taraması (Literature Review)

Lelieveld vd. (2020), çalışmalarında ofis, sınıf, oda gibi tipik iç mekân ortamlarında Aerosol haline getirilmiş SARS-CoV-2 virüslerinin hava yoluyla bulaşmasındaki rolü tartışılmıştır. Araştırmada aerosoller yoluyla ev içi virüs enfeksiyonuna karşı hafifletme önlemlerinin etkinliği hakkında bilgi sağlamayı amaçlanmıştır. Araştırmada oda boyutu, maruz kalan denek sayısı, inhalasyon hacmi ve solunum ve seslendirmeden aerosol üretimi gibi ayarlanabilir parametrelere dayalı olarak, aerosol haline getirilmiş virüslerden iç mekân enfeksiyon riskini tahmin etmek için basit, şeffaf ve kolayca ayarlanabilen bir elektronik tablo algoritması geliştirilmiştir. Araştırma sonuçları kapalı ortamda hava yoluyla bulaşmanın önemli bir faktör olduğunu doğrulamaktadır. Belirsizliklere rağmen, dış hava ile aktif havalandırma ve hava filtreleme gibi farklı etki azaltma önlemleri için öngörülen kısmi azalmaların olduğu görülmüştür (Lelieveld et al., 2020).

Dokuz vd. (2020) çalışmalarında, hava kirletici parametrelerin tahmin edilmesi, çevreye olan etkileri, özellikleri ve değerlendirilmesinde uygulanan makine öğrenmesi yöntemlerinin neler olduğuna dair detaylı sonuçlar vermiştir. Bu araştırma, hava kalitesini iyileştirmek ve sürdürülebilir bir çevrenin oluşturulabilmesi için hangi yöntem ve hangi parametrelerin kullanılması gerektiği sorusuna cevap aramaktadır. Veri hacminin büyüklüğü seçilen yöntemin başarısını etkilediği gözlemlenmiştir. Hava kalitesini belirleyen parametrelerin değerlerinin doğru hesaplanabilmesi için ortamda yeterli istasyon sayısı ve istasyonların konumları önem taşımaktadır. Uygulama alanından toplanacak verilerin kalitesi, düzenliliği ve

hassasiyeti çalışmanın doğru sonuçlar verebilmesi için önemli olduğu sonucuna varılmıştır. (Dokuz et al., 2020) Irmak ve Aydilek hava kalitesini ölçmek amacıyla yaptıkları çalışmada Adana ili valilik istasyonuna ait azot dioksit (NO₂), ozon (O₃), partikül madde (PM₁₀), karbon monoksit (CO) ve kükürt dioksit (SO₂) gibi hava kirlenmelerin ölçüm değerlerine ait veriler kullanılmıştır. (Irmak and Aydilek, 2019). Gültepe (2019) çalışmasında Kastamonu ili ele alınarak, çeşitli makine öğrenmesi algoritmaları ile nem, PM₁₀, rüzgâr yönü, SO₂, hava basıncı, rüzgâr hızı ve hava sıcaklığı gibi meteorolojik parametreleri kullanarak hava kirliliği tahmini yapacak modeller tasarlanmıştır. (Gültepe, 2019). Tahmin modellerinde, Yapay Sinir Ağları, Basit Bayes, Karar Ağacı, Lineer Regresyon, SVM, K-En Yakın Komşu, Rastgele Orman, Lojistik Regresyon ve diğer regresyon algoritma yöntemleri kullanılmıştır. Çalışma süreleri ve hata oranları bakımından algoritmaların başarı değerleri kıyaslanmıştır.

Karakuş ve Yıldız (2019) çalışmalarında Sivas kent merkezindeki hava kirliliği değerlendirilmiş ve hava kalite indeksi (HKİ) hesaplanmıştır. Üç adet hava kalitesi izleme istasyonu kent merkezine konumlandırılarak hava kirlenme parametrelerinin çoklu regresyon yöntemi ile HKİ ve meteorolojik parametreler (rüzgâr hızı, bağıl nem ve sıcaklık) arasındaki ilişkileri belirlenmeye çalışılmıştır. (Karakuş and Yıldız, 2019).

Sakhidad Faizi (2021) çalışmasında Ocak 2019 ile Mart 2021 tarihleri arasında Kabil şehrine ait günlük PM_{2.5}, PM₁₀, CO, SO₂, NO₂, O₃ kirlenme ölçümlerinin yanında nem, rüzgâr hızı, sıcaklık, basınç ve çiy noktası parametrelerinden oluşan veri setinin makine öğrenmesi yöntemleri ile modellenerek bu modellerden elde edilen başarıların karşılaştırılması hedeflenmiştir. Gauss süreç regresyonu, SVM, karar ağaçları, yapay sinir ağları ve lineer regresyon gibi veri madenciliği yöntemleri kullanılarak hava kalite indeksini tahmin eden modeller kurulmuştur. Hava kirliliği tahmininde elde edilen sonuçlara göre Gauss Süreç Regresyonuyla tüm veriler için en yüksek uygunluk değeri ve en düşük hata değerleri elde edilmiştir.(Sakhidad Faizi, 2021).

Zhang vd. (2019) çalışmada tahmin ve değerlendirmeden oluşan yeni bir hava kalitesi erken uyarı sistemi geliştirilmiştir. İlk olarak, gelişmiş veriler ön işleme teknolojisi güçlü sürü zekası algoritması, Balina Optimizasyon Algoritması (WOA) ve verimli yapay sinir ağı ile birleştirilmiş bir tahmin modelini oluşturulmuştur. Ardından, tahmine dayalı sonuçlar, sezgisel hava kalitesi bilgileri ve ilgili önlemleri sunan bulanık kapsamlı değerlendirme yöntemiyle analiz edilmiştir. Bu çalışmada, Pekin, Tianjin ve Shijiazhuang'da altı ana hava kirlenme PM_{2.5}, PM₁₀, NO₂, SO₂, CO ve O₃ seçilmiştir. (Mo et al., 2019)

Balta (2019) çalışmasında sınıf gibi kapalı ortamlardaki bütün konfor parametrelerinin birlikte değerlendirilerek hava kalitesini izleme sistemi ile kapalı bir mekandaki insanlar için en temiz hava kalitesinin sağlanması hedeflenmiştir. Sınıflardaki sıcaklık, hava akışı, CO₂

konsantrasyonu ve nem değerleri tasarlanan iç ortam hava kalitesi izleme sistemi ile anlık ölçüm sonuçlarını sağlayarak iç hava kalitesinin tespit edilmesini sağlamıştır. Kapalı ortam çevresel kalite bilgisi (IEQ) değeri, sınıflarda bulunan öğrencilere yapılan anket ve ölçüm sonuçlarının değerlendirilmesi ile kurulan bulanık sistem sayesinde veriler anlık analiz edilerek hesaplanmıştır. (Balta, 2019)

Santos vd. (2020), çalışmada yoğun bakım ünitesinde ve tüm hastane ortamında koronavirüs hastalığını azaltmak için enfeksiyon riskini en aza indiren ısıtma, havalandırma ve iklimlendirmenin rolünü vurgulamaktadır. Sonuç olarak, nemin insan konforu üzerinde sağlık sorununda daha az etkisi olduğu saptanmıştır. Düşük sıcaklık cansız yüzeylerde canlı virüslerin kalıcılığını artırırken yüksek sıcaklıklar korona virüslerin kalıcılığını azaltmaktadır. (Santos et al., 2020)

Zhang ve arkadaşlarının 1236 bölge için yaptığı araştırmada COVID-19'un bulaşmasında hava koşullarının etkisi saptanmaya çalışılmıştır. Büyük ölçekli uydu verileri, sıcaklık ve bağıl nemin COVID-19 yayılması üzerindeki etkilerini ve mevsimsel döngülere göre olası bulaşma riskini araştırmak için bir regresyon analizi modeliyle bu verilerle birleştirilmiştir. Sonuç olarak, sıcaklık ve bağıl nemin dünya genelinde COVID-19 bulaşması ile negatif ilişkili olduğunu göstermektedir. Daha yüksek sıcaklık ve daha yüksek nemin iletimi azaltabileceği bulunmuştur. (Zhang et al., 2021)

Gupta vd., çalışmalarında sıcaklık, güneş ışığı saatleri ve nem dahil olmak üzere farklı hava faktörlerinin etkisi değerlendirilerek derin transfer öğrenme tabanlı kapsamlı bir analiz gerçekleştirilmektedir. Çalışmadaki temel teori, COVID-19 salgınında pozitif vaka sayısı ile virüslerin iklimle yayılması arasında mevsime dayalı bir model gösterdiği varsayımdır. Çalışma sonucunda yapılan deneysel sonuçlardan sıcaklık, rüzgâr hızı ve güneş ışığı saatlerinin COVID-19 vakaları ve ölümleri üzerinde önemli bir etkisi olduğu gösterilmiştir. Konvolüsyonel sinir ağının rekabetçi modelden daha iyi performans gösterdiği sonucuna varılmıştır. (Gupta et al., 2021)

Makine öğrenmesi algoritmaları güncel çalışmalarda ve farklı bir çok alanda kullanılmaya devam edilmektedir. ((Eren et al., 2023; Aksangür et al., 2022).


3. Makine öğrenmesi Algoritmaları (Machine Learning Algorithms)

Büyük veriden deneyim yoluyla öğrenen ve bu öğrendikleriyle otonom davranış gösterebilen çeşitli algoritmaların oluşturulmasına makine öğrenmesi denir. Makine öğrenmesi modelleri ile kendi kendine karar alabilen otonom akıllı sistemler yapılabilmektedir. Naive bayes, yapay sinir ağları, k-means, karar ağaçları ve çeşitli regresyon algoritmaları, model eşleştirme ve istatistiksel analiz yöntemleri kullanılarak geçmiş verilerden öğrenebilmektedir. Daha sonra öğrendiği bu


bilgileri kullanarak bir model oluşturur. Oluşturulan bu model ile gelecek verilere ait tahminlerde bulunur. Makine öğrenmesinin temel omurgası veridir. Makine öğrenmesi algoritmaları, çözmeleri amaçlanan görev veya sorun türlerine, girdi ve çıktılara, yaklaşımlarına ve veri türlerine göre çeşitlilik gösterirler. Makine öğrenmesi, 1) Denetimli Öğrenme 2) Denetimsiz Öğrenme 3) Yarı denetimli Öğrenme, 4) Pekileştirmeli Öğrenme olmak üzere temel alt sınıflara ayrılır. Çalışma kapsamında kullanılan üç farklı makine öğrenmesi algoritması aşağıda açıklanmıştır.

3.1. Yapay Sinir Ağları (Artificial Neural Networks)

İleriye ve geriye dönük besleme olacak şekilde tasarlanan yapay sinir ağları, insan beyninde bulunan nöronların çalışma prensibi şeklinde modellenmiştir. Öğrenebilen bir algoritma olan yapay sinir ağları birbirlerine bağlı düğümler grubu şeklindeki yapısı (Kulkarni et al., 2017)




Şekil 1'deki şekilde kurulur. Bu şemada her düğüm bir nöronu ve her ok nöronlar arasındaki bağlantıyı temsil eder. Yapay sinir ağı yapısı kurulduktan sonra giriş verileri ve çıkış verileri kıyaslanarak modelin eğitilme süreci başlatılır. Her aşama sonrasında doğru veriye daha fazla yaklaşılr. Çıktı değerleri kontrol edilerek hangi modelin en uygun model olduğu bulunarak öğrenme işlemi tamamlanır. Öğrenme işlemi tamamlandıktan sonra yapay sinir ağı modeli ile test verisi tahmin edilir. (Kulkarni et al., 2017)



Şekil 1: Yapay Sinir Ağları Modeli (Artificial Neural Networks Model) (Kulkarni et al., 2017)

3.2. Destek Vektörleri Makinaları (Support Vector Machines)

Verileri farklı sınıflara ayırmak ve sınır aralığını en üst düzeye çıkarabilmek için destek vektör makinesi algoritması karar sınırı belirler. Bu karar sınırına en yakın iki nokta arasında eşit uzaklıktan geçecek şekilde vektörler çizilir. Çizilen vektörler arasından modeli en iyi tanımlayan ve sınıflandıran destek vektörü seçilir. Vektörler lineer, radyal, sigmoid gibi çeşitlerde oluşturulabilir. Sınıflandırma ve regresyon için kullanılabilen destek vektör makine modelleri bir dizi eğitim verisi verildiğinde çizilen vektörün konumuna göre oluşturulan kategorilerde tahmini sınıflandırma yapabilmektedir. (Chang and Lin, 2011) Şekil 2 de çizilen vektörler yardımı ile nasıl verilerin iki kümeye ayrıldığı gösterilmektedir.



Şekil 2: Destek Vektör Makine Modeli (Support Vector Machines Model) (Burges, 1998)


3.3. Karar Ağacı Algoritması (Decision Tree Algorithm)

Karar ağaçları, karar alma aşamasında seçenek sayısının çok olduğu durumlarda en yaygın biçimde kullanılan bir sınıflandırma yöntemidir. İnsan gözü ile kolay bir şekilde yorumlanabildiği için sıklıkla tercih edilmektedir. Karar ağacı modelinde, öznelikler ağacın iç düğümünde temsil edilmektedir ve her yaprak düğümün bir sınıf etiketine karşılık gelmektedir. Entropi yöntemi ile sınıflar belirlenen sıralamaya ağaçta dallandırılarak tahmin sonuçları elde edilir. Şekil 3'te örnek bir karar ağacı modeli verilmiştir.

Yapay sinir ağı ve diğer makine öğrenmesi algoritmaları kullanılarak sensörün bu durum değişikliklerini tespit etmesi hedeflenmiştir.

Çalışmamızda sensör ölçümleri 2K-02 kodlu sınıfta 40 kişilik bir sınıf mevcuduna sahip Üretim Planlama ve Kontrol dersinde iki farklı konumda yapılmıştır. Örnek veri setimiz 3128 satırdan oluşmaktadır. Sınıftaki ölçümler devam ederken farklı zamanlarda camlar açılarak sınıf havalandırılmıştır. Ayrıca ders arası gibi zamanlarda ortamdaki kişi sayısının azalması sebebiyle ölçüm değerlerinde değişiklikler gözlenmiştir. Sensör yardımıyla yaklaşık 3 sn aralıklar ile sınıf ortamının nem, sıcaklık, CO₂, hava kalite ve basınç değerleri ölçülmüştür. Camların açılarak sınıfın havalandırıldığı zamanlar durum parametresi altında havalandırma olarak gösterilmiştir. Makine öğrenmesi ve yapay sinir ağları yöntemleri kullanılarak havalandırma durumları HAVALANDIRMA (H) ile, normal şartlar altındaki hava ölçümleri NORMAL (N) ile gösterilmiştir. Yapılan çalışmalar ile sınıftaki hava kalitesinin belirlenmesinde belirleyici faktörün karbondioksit (CO₂) olduğu tespit edilmiştir. Verilerimiz arasındaki sürenin kısa olması sebebiyle ölçülen CO₂ miktarların 3, 5, ve 10'arlık olarak ortalaması alınmıştır. Böylelikle ölçüm değerleri 3 şekilde incelenerek daha doğru tahminlerin yapılması sağlanmıştır. Yapılan ölçümler ile hazırlanan veri seti Tablo 1: Veri Seti (Data set)'de gösterilmiştir.

Süre (sn)	Nem	Sıcaklık	CO2	Hava Kalite	Basınç	3'lü Ortalama	5'li Ortalama	10'lu Ortalama	Durum
7,264	47,2	29,2	400	78	1164,25				0
8,947	47,2	29,2	400	79	1163,67				0
10,635	47,2	29,2	400	94	1164,32	400			0
12,318	47,2	29,2	400	77	1165,15	400			0
14,006	47,1	29,2	400	75	1163,65	400	400		0
15,689	47,1	29,2	400	90	1159,62	400	400		0
17,376	47,1	29,2	400	80	1160,47	400	400		0
19,059	47,1	29,2	400	96	1161,36	400	400		0
20,747	47,1	29,2	400	77	1160,94	400	400		0
22,43	47,1	29,2	408	77	1159,63	402,7	401,6	400,8	0
24,117	47,1	29,2	400	89	1158,67	402,7	401,6	400,8	0
25,801	47,1	29,2	410	77	1159,29	406	403,6	401,8	0
27,488	47,1	29,2	405	76	1161,27	405	404,6	402,3	0
29,171	47,1	29,2	400	75	1162,46	405	404,6	402,3	0



Şekil 3: Karar Ağacı Modeli (Decision Tree Model) (Uysal and Güyer, 2014)

4. Vaka Çalışması (Case Study)

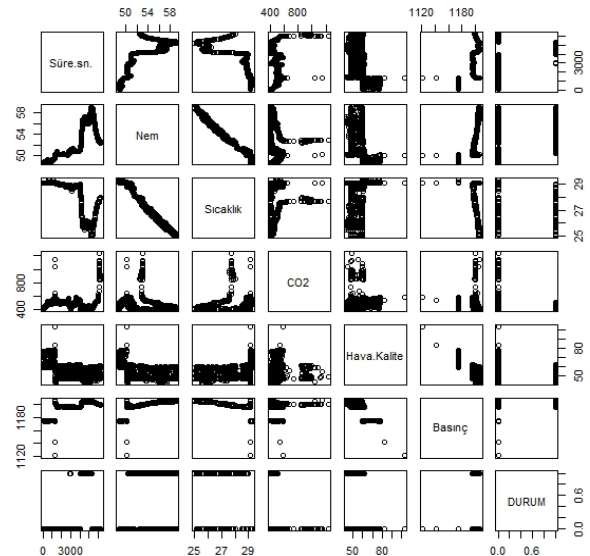
4.1. Havalandırma Tahmin Uygulaması Veri Analizi (Ventilation Forecasting Application Data Analysis)

Kampüs içi kapalı alanlarda hava kalitesinin modellenmesi ve karar destek sisteminin geliştirilmesi için İstanbul Medeniyet Üniversitesi Dekanlığında yer alan hava kalitesi ölçüm cihazı ile 2021 Kasım ayında sıcaklık, nem, CO₂, Basınç (p) ve havadaki kirlenici partikül değerlerinin (aq) ölçümleri yapılmıştır. Bu ölçümler belli saniye aralıkları ile ölçülerek kaydedilmiştir. 2021 Kasım ayında yapılan çalışmalarımıza ek olarak hava kalitesini etkileyen parametrelere ait yeni veriler toplanarak veri seti artırılmıştır. Yeni veri değerleri kapalı bir sınıf ortamında ders işleyen öğrencilerin bulunduğu bir sınıftan toplanmıştır. Veriler toplanırken sınıf ortamında bazı farklı senaryolar oluşturularak sensörün bu durum karşısında nasıl bir tepki verdiği ölçülmeye çalışılmıştır. Kişi sayısı artışı, cam veya kapının açılması ve ders arası süresinin uzatılması gibi senaryolar oluşturulmuştur.



Tablo 1: Veri Seti (Data set)

Veri setindeki nem, sıcaklık, CO₂, hava kalitesi, basınç ve durum parametrelerinin birbirleriyle ilişkilerinin gösterildiği korelasyon grafikleri Pearson algoritması kullanılarak R programlama dili ile çizilerek Şekil 4: Parametre İlişki Matrisi Grafikleri (Parameter Relationship Matrix Charts) ve Şekil 5: Parametre Korelasyon Matrisi (Parameter Correlation Matrix) te gösterilmiştir.

Şekil 4: Parametre İlişki Matrisi Grafikleri (Parameter Relationship Matrix Charts)



Veri setinde beş parametre arasında en yüksek pozitif ilişki 0.74 değeriyle basınç ve nem miktarı parametreleri arasındadır. Parametreler arasında en düşük negatif ilişki ise -0.99 değeriyle nem ve sıcaklık parametreleri arasındadır. Şekil 4'te beş parametre arasındaki korelasyon değerleri gösterilmiştir.



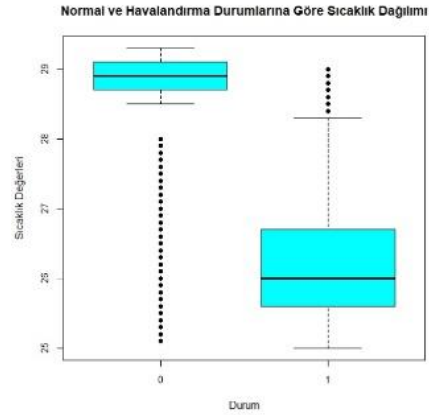
Şekil 5: Parametre Korelasyon Matrisi (Parameter Correlation Matrix)

Yapay sinir ağları, destek vektör makineleri ve karar ağacı gibi makine öğrenmesi yöntemleri kullanılarak havalandırma durumlarının doğru bir şekilde tahmin edilmesi amaçlanmıştır. Tahmin işlemleri için 3128 satırdan oluşan veri setinin %70'i eğitim verisi olarak kullanılmıştır. Tablo 2'de veri setine ait tanımlayıcı istatistik verilmiştir.

Tablo 2: Veri seti Parametrelerin İstatistiksel Değerleri (Statistical Values of Parameters)

	Min	Ortalama	Max	Medyan	Std
Nem	48,7	52,07	59,1	50,8	3,02
Sıcaklık	25	28,8	29,3	28,8	1,36
CO2	400	495,6	1235	495	95,23
Hava Kalite	43	53,19	103	49	7,53
Basınç	1121	1194	1207	1196	10,63

3'lü Ortalama	400	495,5	1158,7	494,3	94,4
5'li Ortalama	400	495,4	1120,6	494,8	93,83
10'lu Ortalama	400,4	495,2	1036,6	495	92,71



Şekil 6: Sıcaklık Parametresinin Havalandırma Durumuna Göre Boxplot Grafikleri (Boxplot Plots of Temperature Parameters by State)

Veri setindeki CO₂ miktarının zamansal olarak değişiminin gösterildiği grafik Şekil 7'de verilmiştir. Grafik üzerinde havalandırma durumları turuncu renk, normal durumlar yeşil ile gösterilmiştir. Grafikte de görüldüğü gibi CO₂ miktarının en düşük olduğu seviyeler yaklaşık olarak havalandırma durumları olmaktadır.

Şekil 7: CO₂ değişimlerinin Nokta Grafiği (Point Graph of CO₂ Changes)

5.2. Havalandırma Tahmini (Ventilation Estimation)

5.2.1. Karar Ağaçları Tahmini (Decision Trees Estimation)


Eğitim verisinde ve test verisinde CO₂ değerlerinin kümülatif olarak toplandığı 3 yeni sütun eklenmiştir. CO₂ değerleri 3'lü, 5'li ve 10'lu olmak üzere 3 farklı sütunda toplanmıştır. Karar ağacı metodu bu üç sütun için ayrı ayrı çalıştırılarak aralarından en iyi tahmin sonucu elde edilmeye çalışılacaktır.

Tablo 1: Veri Seti (Data set)'de verilen veri setinde ortamın havalandırıldığı zamanların 1 ile belirtildiği "Durum" sütunu faktör olarak seçilmiştir. R programı bilinmeyen değerlerin (olmayan değerlerin) bulunduğu parametrelerde makine öğrenmesi yöntemleri kullanılırken hata verdiği için CO₂ değerindeki bilinmeyen verilerin silinmesi gerekmektedir. Bu sebeple CO₂ miktarının 3'erli olarak toplandığı 3'lü ortalama sütunu için ilk iki verinin olmamasından dolayı silinmesi gerekmektedir. 5'li ortalama sütunu için ilk 4 veri ve 10'lu ortalama için ilk 9 verinin silinmesi gerekmektedir.

Tablo 6’da görüldüğü gibi CO₂ değerlerinin 3’erli olarak toplandığı 3’lü ortalama sütunu için karar ağacı sonucunda CO₂ değeri havalandırma durumlarının tahmininde en etkili faktördür. Karar ağacı metodunun uygulanması sonucunda test verisindeki %72,49 doğruluk oranıyla 311 veri normal olarak doğru tahmin edilmiştir. 115 veri havalandırma iken normal olarak ve 3 veri normal iken havalandırma olarak yanlış tahmin edilmiştir. CO₂ değerlerinin 5’erli olarak toplandığı 5’li ortalama için %72,36 doğruluk oranıyla test verisindeki 309 veri normal olarak doğru tahmin edilmiştir. 115 veri havalandırma yapılmış iken normal olarak ve 3 veri normal iken havalandırma var diyerek yanlış tahmin edilmiştir. CO₂ değerlerinin 10’arlı olarak toplandığı 10’lu ortalama sütunu için karar ağacı metodunun uygulanması sonucunda %72,74 doğruluk oranıyla test verisindeki 307 veri normal olarak doğru tahmin edilmiştir. 115 veri havalandırma iken normal olarak yanlış tahmin edilmiştir. Havalandırma olarak hiçbir veri tahmin edilmemiştir

Karar ağacı algoritmasıyla elde edilen en iyi tahmin olan 10’lu ortalama olarak CO₂ miktarının zamana göre değişimi Şekil 8’deki grafikte nokta grafiğiyle görselleştirilmiştir. 10’lu ortalama parametresi kullanılarak karar ağacı yöntemiyle havalandırma zamanlarının tahminleri turuncu renkte gösterilmiştir. Fakat karar ağacı metoduyla yapılan tahminde tüm tahminler normal (yeşil) olarak tahmin edilmiştir.

Şekil 8: 10’lu ortalama Parametresi İçin Karar Ağacı Yöntemi ile CO₂ Değişimlerinin Nokta Grafiği (Point Graph of CO₂ Changes with Decision Tree Method for Average of 10 Parameters)



Tablo 3’de uygulanan karar ağacı yöntemlerinin 3’lü, 5’li ve 10’lu ortalama tahminleri ile elde edilen hata metrik performansları yer almaktadır. Ortalama Karesel Hata (Mean Squared Error-MSE) ve doğruluk değerleri tablodaki gibi hesaplanmıştır. Tablodan da görüldüğü

gibi en doğru tahmin sonucunun elde edildiği parametre 10’lu ortalama olmuştur.

Tablo 3: Karar Ağacı Yöntemi Hata Metrik Performansları (Decision Tree Method Error According to Different Error Metrics)

	MSE	Doğruluk
3’lü Ortalama	0,275	0,7249
5’li Ortalama	0,2763	0,7236
10’lu Ortalama	0,2725	0,7274

5.2.2. Yapay Sinir Ağları ile Tahmin (Artificial Neural Networks Estimation)


Yapay sinir ağları metodu kullanılarak farklı katmanlara sahip modeller oluşturulmuştur. Eğitim verimizdeki veri sayısı fazla olduğu için mimari 1 ve (2,1) olacak şekilde oluşturulmuştur. Bu modeller arasından en iyi tahmin performansına sahip yöntem seçilecektir.

Yapay Sinir ağları mimarisi ile ilgili olarak kullanılan mimarisi açısından gizli katman (Hidden) olarak hem tek katmanlı ve (2,1) katman kullanılmıştır. Eşik değeri (Threshold) ise 0.03 iken tek tekrarlanma (rep=1) yeterli olmuştur. Başlangıç değerleri (Startweights) önceden belirlenmemiş olup öğrenme oranı olarak (Learningrate) 0.04 belirlenmiştir. Aktivasyon fonksiyonu (act.fct) hiperbolik tanjant, hata fonksiyonu (err.fct) olarak ise hataların karelerinin toplamı (sse) kullanılmıştır.

Tek katmanlı yapay sinir ağı modelinde 3’lü ortalama parametresi için %78.32, 5’li ortalama parametresi için 79.16, 10’lu ortalama parametresi için 78.44 doğruluk oranıyla tahmin yapılmıştır. Aralarından en iyi tahmini yapan model 5’li ortalama parametrelili model olmuştur. En iyi model sonucunda test verisindeki 279 veri normal olarak ve 59 veri havalandırma olarak doğru tahmin edilmiştir. 33 veri havalandırma iken normal olarak ve 56 veri normal iken havalandırma olarak yanlış tahmin edilmiştir.

2 gizli katmanlı (2,1) nörondan oluşan yapay sinir ağı modelinde 3’lü ortalama parametresi için %84.15, 5’li ortalama parametresi için %83.37, 10’lu ortalama parametresi için %76.06 doğruluk oranıyla tahmin yapılmıştır. Aralarından en iyi tahmini yapan model 3’lü ortalama parametrelili model olmuştur. En iyi model sonucunda test verisindeki 300 veri normal olarak ve 61 veri havalandırma olarak doğru tahmin edilmiştir. 14 veri havalandırma iken normal olarak ve 54 veri normal iken havalandırma olarak yanlış tahmin edilmiştir.

Yapay sinir ağı algoritmasıyla elde edilen 5'li ortalama'li olarak CO₂ miktarının zamana göre değişimi Şekil 9 'da nokta grafiğiyle görselleştirilmiştir. 5'li ortalama parametresi kullanılarak yapay sinir ağı yöntemiyle havalandırma zamanlarının tahminleri turuncu renkte gösterilmiştir.



Şekil 9: 5'li ortalama Parametresi İçin 2 Gizli Katmanlı Yapay Sinir Ağı ile CO₂ Değişimlerinin Nokta Grafiği (Point Graph of CO₂ Changes with artificial Neural Network for Average of 5 Parameters)

Tablo 4' de uygulanan farklı katmanlı yapay sinir ağları yöntemlerinin 3'lü, 5'li ve 10'lu ortalama tahminleri ile elde edilen hata metrik performansları yer almaktadır. 2 (gizli) katmanlı model tek katmanlı modele göre daha iyi sonuçlar vermiştir. Yapay sinir ağları yöntemiyle en doğru tahmin sonucunun elde edildiği 2 (gizli) katmanlı 3'lü ortalama modeli olmuştur.

Tablo 4: Tek Katmanlı ve (2,1) Katmanlı Yapay Sinir Ağı Modelinin Farklı Parametrelere Göre Hata Metrikleri (Error Metrics of Single-Layer and (2,1) hidden layer Neural Network Model by Different Parameters)

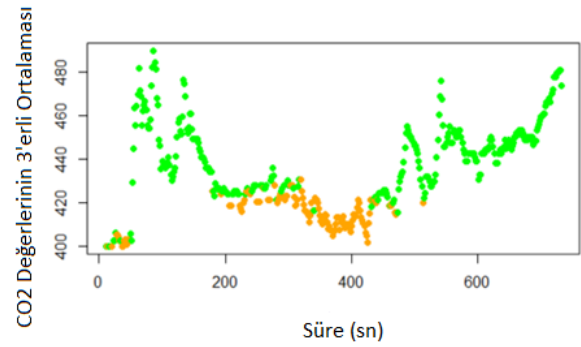
	MSE	MAPE	Doğruluk
1 Katman			
Yapay Sinir Ağı 3'lü	0,2167	0,1527	0,7832
Yapay Sinir Ağı 5'li	0,2084	0,1428	0,7916
Yapay Sinir Ağı 10'lu	0,2156	0,1492	0,7844
c(2,1) Katman			
Yapay Sinir Ağı 3'lü	0,1585	0,0956	0,8415
Yapay Sinir Ağı 5'li	0,1663	0,1007	0,8337
Yapay Sinir Ağı 10'lu	0,2393	0,2014	0,7606

5.2.3 Destek Vektör Makine ile Tahmini (SVM Estimation)

Destek vektör makine metodu kullanılarak 3'lü, 5'li ve 10'lu ortalama ile farklı lineer ve radyal modeller oluşturulmuştur. Lineer modelinde 3'lü ortalama parametresi için 325 vektör, 5'li ortalama parametresi için 324 vektör, 10'lu ortalama parametresi için 327 vektör oluşturulmuştur. Radyal modelinde 3'lü ortalama parametresi için 420 vektör, 5'li ortalama parametresi için 424 vektör, 10'lu ortalama parametresi için 419 vektör oluşturulmuştur. Aralarından en iyi tahmini yapan model %84,12 doğruluk değeriyle 10'lu ortalama parametrelili model olmuştur. Destek vektör metodunun uygulanması sonucunda test verisindeki 284 veri normal

olarak ve 71 veri havalandırma olarak doğru tahmin edilmiştir. 23 veri havalandırma iken normal olarak ve 44 veri normal iken havalandırma olarak yanlış tahmin edilmiştir. Elde edilen sonuçlara göre radyal modellerde, lineer modellere göre daha iyi sonuçlar elde edilmiştir. Aralarından en iyi tahmini yapan model %85,88 doğruluk değeriyle 3'lü ortalama parametrelili model olmuştur. SVM metodunun uygulanması sonucunda test verisindeki 277 veri normal olarak ve 88 veri havalandırma olarak doğru tahmin edilmiştir. 37 veri havalandırma iken normal olarak ve 27 veri normal iken havalandırma olarak yanlış tahmin edilmiştir. Destek Vektör makinesi algoritmasıyla elde edilen en iyi tahmin olan 3'lü ortalama'lu olarak CO₂ miktarının zamana göre değişimi Şekil 20'de nokta grafiğiyle görselleştirilmiştir. 3'lü ortalama parametresi kullanılarak Radyal yöntem ile havalandırma zamanlarının tahminleri turuncu renkte gösterilmiştir.

Şekil 10: 3'lü ortalama Parametresi İçin SVM Radyal Model ile CO₂ Değişimlerinin Nokta Grafiği (Point Graph of CO₂ Changes with SVM Radial Model for Average of 3 Parameter)



Tablo 5'de uygulanan destek vektör makine yöntemlerinin 3'lü, 5'li ve 10'lu ortalama tahminleri ile elde edilen hata metrik performansları yer almaktadır. Radyal modellerin da yüksek doğrulukta sonuçlar ürettiği görülmektedir.

Tablo 5: Lineer ve Radyal Modellerin Farklı Parametrelere Göre Hata Metrikleri (Error Metrics of Linear and Radial SVM Models According to Different Parameters)

	Vektör Sayısı	MSE	Doğruluk
Lineer Model 3'lü	325	0,1678	0,8322
Lineer Model 5'li	324	0,1733	0,8267
Lineer Model 10'lu	327	0,1587	0,8412
Radyal Model 3'lü	420	0,1491	0,8588
Radyal Model 5'li	424	0,1451	0,8548
Radyal Model 10'lu	419	0,1587	0,8412

Uygulama bölümünde makine öğrenmesi yöntemleri ile elde edilen tahminlerin karışıklık matrisleri Tablo 6 'da

gösterilmiştir. Elde edilen tahmin sonuçlarının doğruluk yüzdeleri

Tablo 6: Makine Öğrenmesi Yöntemleri ile Elde Edilen Karışıklık Matrisleri (Response Matrices Obtained by Machine Learning Methods)

		Normal (N)	Havalandırma (H)
Karar Ağacı 3'lü	N	311	3
	H	115	0
Karar Ağacı 5'li	N	309	3
	H	115	0
Karar Ağacı 10'lu	N	307	0
	H	115	0
Yapay Sinir Ağı 3'lü	N	276	55
	H	38	60
Yapay Sinir Ağı 5'li	N	279	56
	H	33	59
Yapay Sinir Ağı 10'lu	N	272	56
	H	35	59
(2,1) Yapay Sinir Ağı 3'lü	N	300	54
	H	14	61
(2,1) Yapay Sinir Ağı 5'li	N	297	56
	H	15	59
(2,1) Yapay Sinir Ağı 10'lu	N	238	32
	H	69	83
SVM Lineer Model 3'lü	N	284	42
	H	30	73
SVM Lineer Model 5'li	N	282	44
	H	30	71
SVM Lineer Model 10'lu	N	284	44
	H	23	71
SVM Radyal Model 3'lü	N	277	27
	H	37	88
SVM Radyal Model 5'li	N	275	25
	H	37	90
SVM Radyal Model 10'lu	N	272	32
	H	35	83

5. Sonuç (Conclusion)

İstanbul Medeniyet Üniversitesi zeki kampüs kapsamında yapmış olduğumuz çalışmada havalandırma durumlarının tahmini için geliştirilen yapay sinir ağları, destek vektör makineleri ve karar ağacı modelleri ile karar destek sistemi oluşturulması hedeflenmiştir. Verilerin kapsayıcılığının ve sayısının artırılması ile makine öğrenmesi modelleri hava kalitesinin tahmin edilmesinde daha iyi sonuçlar vermiş ve makine öğrenmesi metotları ile oluşturulan karar destek sistemleri kabul edilebilir doğrulukta tahmin sonuçları üretmiştir. Havalandırma zamanlarını en iyi tahmin eden makine öğrenmesi yöntemi 0,85 doğruluk ile radyal SVM modeli olmuştur. En kötü tahmin yöntemi ise 0,72 doğruluk oranıyla karar ağacı yöntemi olmuştur. Karar ağacı yöntemi havalandırma durumlarını tespit etmekte zorlanmıştır. Yapay sinir

ağları kapsamında oluşturulan ilk mimaride doğruluk oranları 0,74 iken ikinci mimaride 0,84 oranına yükselmiştir. Bu arada farklı yapay sinir ağları yapıları deneyerek doğruluk oranlarının artırılacağı görülmüştür. Mimari kümülatif ortalamalı olarak eklediğimiz 3'lü,5'li ve 10'lu CO2 parametresi havalandırma durumlarının daha doğru bir şekilde tahmin edilmesine katkı sağlamıştır. Çünkü bir zamandaki hava kirliliğini kendinden önce ölçülen CO2 miktarları da etkilemektedir. Ortalama olarak eklenen CO2 değerlerine kendi içinde bakıldığı zaman üç yöntem için de doğruluk oranlarının birbirine yakın olduğu görülmüştür.

Yaptığımız bu çalışma ile makine öğrenmesi teknikleriyle sensör verilerinin modellenmesi ve havada gerçekleşen ani değişikliklerin (odanın havalandırılması, insan sayısının artması gibi) model tarafından tespitini sağlanmıştır. Çalışmanın sonucu olarak kabul edilebilir aralıkların dışına çıkan hava kalitesi durumlarının tespiti sonucunda odanın ne zaman havalandırılacağına karar verilebilmektedir. Bu çalışmada kurduğumuz modeller kampüs dışında toplu taşıma araçları, iş yerleri, ofis, restoran, kafe, özel araçların havalandırma sistemlerinde de kullanılabilir. Bu araştırma ile üniversite kampüslerinde virüs bulaşma riski en aza indirilerek güvenli bir şekilde öğrenci ve öğretmenlerin eğitim hayatlarına devam etmesine katkı sağlanmıştır. Çalışmanın bir sonraki aşamasında kapalı alanlarda yerleştirilecek olan sensörlerin sayılarının optimize edilmesi, konularının belirlenmesi konularına ağırlık verilecektir. Yöntem olarak ise özellikle sensör yerleşim problemi için metasezgisel yöntemlerden yararlanılacaktır.

Kaynakça (References)

- Aksangür, İ. et al. (2022) Evaluation of data preprocessing and feature selection process for prediction of hourly PM10 concentration using long short-term memory models. Environmental Pollution. [Online] 311119973.
- Balta, D. (2019) Dağıtık Sensör Sistemleri Mimarisi ile Bulanık Mantık Temelli ve Çevrimiçi Kapalı Ortam Hava Kalitesi İzleme Sistemi Geliştirilmesi.
- Burges, C. J. C. (1998) A tutorial on support vector machines for pattern recognition. Data Mining and Knowledge Discovery. [Online] 2 (2), .
- Chang, C. C. & Lin, C. J. (2011) LIBSVM: A Library for support vector machines. ACM Transactions on Intelligent Systems and Technology. [Online] 2 (3), .
- Dokuz, Y. et al. (2020) Hava Kalitesi Parametrelerinin Tahmini ve Mekansal Dağılımı İçin Makine Öğrenmesi Yöntemlerinin Kullanılması. Ömer

- Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi. [Online]
- Elibol, H. (2021) Kapalı Mekanlarda Sosyal Mesafe Kuralı Ne Kadar Önemli [online]. Available from: <https://www.hurriyet.com.tr/gundem/kapali-mekanlarda-sosyal-mesafe-kurali-ne-kadar-onemli-41801992> (Accessed 2 February 2022).
- Eren, B. et al. (2023) Predicting next hour fine particulate matter (PM2.5) in the Istanbul Metropolitan City using deep learning algorithms with time windowing strategy. *Urban Climate*. [Online] 48101418.
- Gültepe, Y. (2019) Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. *European Journal of Science and Technology*. [Online] 8–15.
- Gupta, Y. et al. (2021) Impact of Weather Predictions on COVID-19 Infection Rate by Using Deep Learning Models. *Complexity*. [Online] 2021.
- Irmak, M. E. & Aydilek, İ. B. (2019) Hava Kalite İndeksinin Tahmin Başarısının Artırılması için Topluluk Regresyon Algoritmalarının Kullanılması. *Academic Platform Journal of Engineering and Science*. [Online] 507–514.
- Karakuş, C. B. & Yıldız, S. (2019) Hava Kalite İndeksi İle Meteorolojik Parametreler Arasındaki İlişkinin Çoklu Regresyon Yöntemi İle Belirlenmesi. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*. [Online]
- Kulkarni, P. S. et al. (2017) Artificial Neural Networks for Construction Management: A Review. *Journal of Soft Computing in Civil Engineering*. [Online] 1 (2), .
- Lelieveld, J. et al. (2020) Model calculations of aerosol transmission and infection risk of covid-19 in indoor environments. *International Journal of Environmental Research and Public Health*. [Online] 17 (21), 1–18.
- Mo, X. et al. (2019) A novel air quality early-warning system based on artificial intelligence. *International Journal of Environmental Research and Public Health*. [Online] 16 (19), .
- Sakhıdad Faız (2021) Kabil'in Hava Kalitesi Tahmininde Makine Öğrenmesi Algoritmalarının Kullanılması.
- Santos, A. F. et al. (2020) Best Practices on HVAC Design to Minimize the Risk of COVID-19 Infection within Indoor Environments. *Brazilian Archives of Biology and Technology*. [Online] 631–11.
- Zhang, C. et al. (2021) The role of weather conditions in COVID-19 transmission: A study of a global panel of 1236 regions. *Journal of Cleaner Production*. [Online] 292.