

## IoT Sistemleri ve Makine Öğrenmesi Teknikleri Kullanılarak Boğulma ve Yangın Risklerinin Tahmini

Leonel FOKOUONG NOBOSSE<sup>1</sup>, Zuhale CAN<sup>2\*</sup>

<sup>1</sup> Bilgisayar Mühendisliği Bölümü, Fen Bilimleri Fakültesi, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye

<sup>2</sup> Bilgisayar Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye

<sup>1</sup>leonelfokouong@gmail.com, <sup>2</sup>zcan@ogu.edu.tr

(Geliş/Received: 26/10/2024;

Kabul/Accepted: 26/02/2025)

**Öz:** Bu çalışmada, makine öğrenmesi (ML) ve Nesnelerin İnterneti (IoT) teknolojilerini kullanarak boğulma ve yangın risklerinin tahmin edilmesi amaçlanmaktadır. Boğulma ve yangın olayları, ciddi, can ve mal kayıplarına yol açan tehlikelerdir. Geleneksel yöntemler bu risklerin tahmin edilmesinde yetersiz kalabilirken, ML modelleri kullanarak ve IoT tabanlı sensör verileriyle elde edilen büyük veri kümelerinin analiziyle yüksek doğrulukta tahminler sağlanabilmektedir. Bu çalışmada, IoT sensörlerinden elde edilen veriler üzerinde ML yöntemlerinin karşılaştırmalı bir incelemesi yapılmıştır. Boğulma riskini tahmin etmek için karbon monoksit (CO), duman ve sıvı petrol gazı (LPG) arasındaki korelasyon, yangın riskini tahmin etmek için ise nem, sıcaklık ve duman arasındaki korelasyon kullanılmıştır. Veriler, ön işleme adımları tamamlandıktan sonra, doğrusal regresyon, karar ağaçları ve rastgele orman algoritmalarıyla geliştirilen modellerle eğitilmiştir. Deneysel sonuçlar, karar ağacının %99,99 doğrulukla diğer algoritmaları geride bıraktığını göstermektedir. Geliştirilen modelin yüksek doğruluk oranı ile çalıştığı ve risk yönetimi stratejilerinin geliştirilmesinde önemli bir rol oynayabileceği belirlenmiştir.

**Anahtar kelimeler:** Nesnelerin İnterneti, Çevresel Sensörler, Makine Öğrenmesi, Karar Ağaçları, Risk Tahmini.

### Predicting Suffocation and Fire Risks Using IoT Systems and Machine Learning Techniques

**Abstract:** This study aims to predict suffocation and fire risks using machine learning (ML) and Internet of Things (IoT) technologies. Suffocation and fire incidents are serious dangers that lead to loss of life and property. While traditional methods may be insufficient in predicting these risks, high-accuracy predictions can be achieved by using ML models and analyzing large data sets obtained with IoT-based sensor data. In this study, a comparative study of ML methods was conducted on data obtained from IoT sensors. The correlation between carbon monoxide (CO), smoke, and liquid petroleum gas (LPG) was used to predict the risk of suffocation, and the correlation between humidity, temperature, and smoke was used to predict the risk of fire. After the pre-processing steps were completed, the data were trained with models developed with linear regression, decision trees, and random forest algorithms. Experimental results show that the decision tree outperformed other algorithms by 99.99%. It was determined that the developed model worked with high accuracy rates and could play an important role in the development of risk management strategies.

**Key words:** Internet of Things, Environmental Sensors, Machine Learning, Decision Trees, Risk Prediction.

#### 1. Giriş

Boğulma ve yangın olayları, dünya genelinde önemli sağlık ve güvenlik sorunları arasında yer almakta olup, her yıl milyonlarca insanın hayatını kaybetmesine veya ciddi yaralanmalarına yol açmaktadır. Dünya Sağlık Örgütü'ne (WHO) göre, bu tür olaylar hem can kaybına hem de ekonomik kayıplara neden olmaktadır. Bu çalışmanın amacı, makine öğrenmesi (ML) tekniklerini kullanarak boğulma ve yangın risklerinin tahmin edilmesidir.

Geleneksel yöntemler, boğulma ve yangın risklerini tahmin etmede sınırlı kalabilir. Bu noktada, Nesnelerin İnterneti (IoT) teknolojileri ve ML modelleri, büyük veri kümelerinden elde edilen bilgileri işleyerek daha doğru tahminler yapabilme potansiyeline sahiptir. IoT cihazları ve sensörler, gerçek zamanlı veri toplayarak olayların dinamiklerini anlama ve tahmin etme konusunda önemli bir kaynak oluşturur. Bu çalışma, boğulma ve yangın olaylarına dair verilerin çeşitli IoT sensörleri aracılığıyla toplanması ve bu verilerin ML algoritmaları kullanılarak analiz edilmesi üzerine odaklanmaktadır.

Bu çalışmada, boğulma ve yangın olaylarına ilişkin verilerin analizi için Çevresel Sensör Verileri (Kaggle, 2024) kullanılmıştır. Bu veri setinden sıcaklık, nem, karbon monoksit (CO), sıvılaştırılmış petrol gazı (LPG) ve

\* Sorumlu yazar: zcan@ogu.edu.tr. Yazarların ORCID Numarası: <sup>1</sup> 0009-0001-5709-842X, <sup>2</sup> 0000-0002-6801-1334

duman, verileri seçilmiş ve doğrusal Regresyon, karar ağacı ve rastgele orman gibi ML algoritmaları kullanılarak analizi yapılmıştır. Yöntemlerin performansı doğruluk, ortalama karesel hata, R kare değeri, ortalama mutlak hata ve Karekök Ortalama Kare Hatası ölçütleri kullanılarak değerlendirilmiştir.

Bu çalışmanın literatüre katkısı, boğulma ve yangın risklerinin tahmin edilmesinde ML ve IoT teknolojilerinin etkinliğini ortaya koyarak, bu alanda daha güvenilir ve hızlı tahmin modelleri geliştirilmesine katkı sağlamaktır. Sonuçlar, acil durum müdahale planlarının oluşturulmasında ve risk yönetimi stratejilerinin geliştirilmesinde önemli rol oynayabilir. Geliştirilen modelin yüksek doğruluk oranları ile çalıştığı ve gerçek zamanlı veri analizine dayalı tahminler yaparak boğulma ve yangın gibi olayların etkilerini minimize edebileceği belirlenmiştir.

Bu çalışma, boğulma ve yangın risklerini tahmin etmek için makine öğrenmesi tekniklerini kullanan bir araştırma sunmaktadır. 2. bölümde, IoT ve makine öğrenmesi çevresel izleme, akıllı şehirler, sağlık, tarım, güvenlik gibi çeşitli uygulama alanları ile ele alınmıştır. 3. bölümde, sıcaklık, nem, CO, LPG ve duman gibi sensör verilerinin toplanması ve bu verilerin doğrusal regresyon, karar ağaçları ve rastgele orman algoritmaları kullanılarak analiz edilmesi anlatılmaktadır. 4. Bölümde, yapılan analizlerin sonuçları sunulmuş ve karar ağaçları algoritmasının en yüksek doğruluğu sağladığı belirtilmiştir. Sonuç bölümünde ise, geliştirilen modellerin erken tespit ve hızlı müdahale ile boğulma ve yangın olaylarının etkilerini minimize edebileceği vurgulanmıştır.

## 2. Literatür Özeti

IoT'un boğulma ve yangın risklerinin tahmini alanında olduğu gibi çevresel izleme ve yönetimi, akıllı şehirler ve enerji yönetimi, sağlık ve tıp uygulamaları, tarım ve sürdürülebilirlik, güvenlik ve iletişim ve güven yönetimi, ve bir çok çeşitli alanda uygulama potansiyeli vardır. Bu bölümde açıklanan çalışmalar, farklı teknolojinin sunduğu avantajları ortaya koyarak, IoT'nin disiplinlerarası bir vizyona sahip olduğunu göstermektedir.

Çevresel izleme ve yönetim alanında IoT üzerine çeşitli çalışmalar yapılmıştır. Shaikha ve arkadaşları ile AlZubi, IoT'nin su kaynaklarının izlenmesi ve su kirliliği tedavisindeki potansiyelini vurgularken [1][2], Kagainkar ve arkadaşları, IoT'nin hava kalitesi yönetiminde nasıl kullanılabileceğini ele almıştır [3]. Vo ve arkadaşları, IoT teknolojilerinin deniz ortamındaki uygulamalarını ve bu teknolojilerin çevresel izleme ve yönetim alanındaki faydalarını incelerken [4], Popescu ve arkadaşları, çevresel kirliliğin izlenmesi ve yönetiminde yapay zeka ve IoT teknolojilerinin entegrasyonunu ele almıştır [5].

Akıllı şehirler ve enerji yönetimi altında IoT üzerine farklı alanlarda çalışmalar bulunmaktadır. Khalil ve arkadaşları, IoT'de kaynak keşfi tekniklerinin çeşitliliğini ve avantajlarını incelerken [6], Al-Obaidi ve arkadaşları, IoT'nin enerji verimli binalar ve şehirler için kullanımını araştırmıştır [7]. Musa ve arkadaşları, akıllı IoT sistemleri için açık radyo erişim ağlarının mevcut durumu ve gelecekteki yönelimlerini ele almıştır [8]. Li ve arkadaşları ise, veri merkezli IoT uygulamaları için bulut platformlarına yönelik dinamik bir yaklaşım önermektedir [9].

Sağlık ve tıp uygulamaları alanında IoT çalışmaları çok çeşitlidir. Xiang ve arkadaşları, IoT sağlık sistemlerinde RFID sensörlerinin kullanımını incelemiştir [10], Abdulmalek ve arkadaşları, IoT tabanlı sağlık izleme sistemlerinin yaşam kalitesini artırmadaki rolünü araştırmıştır [11]. Al-rawashdeh ve arkadaşları, akıllı sağlık hizmetleri için IoT'nin benimsenmesi ve uygulamalarını gözden geçirmiştir [12], Hintaw ve arkadaşları, MQTT protokolünün IoT ortamlarındaki güvenlik açıklarını ve bu açıkların nasıl giderilebileceğini tartışmıştır [13].

Tarım ve sürdürülebilirlik alanında IoT üzerine çalışmalar bulunmaktadır. Kumar ve Karthikeyan, tarım sektöründe çevresel koşulların izlenmesi için IoT uygulamalarını incelemiştir [14], Riskiawan ve arkadaşları, yapay zeka destekli IoT sera izleme ve kontrol sistemlerini ele almıştır [15]. Prabu ve arkadaşları, k-NN-SVM algoritmasıyla IoT destekli yeraltı suyu izleme sistemini sürdürülebilir su yönetimi için incelemiştir [16].

Güvenlik ve İletişim üzerine IoT çalışmaları artarak devam etmektedir. Azzedin ve Alhazmi, MQTT protokolü ile IoT'da güvenli veri dağıtım mimarisini ele almıştır [17]. Sharma ve arkadaşları, IoT tabanlı bir orman yangını tespit sisteminin tasarımını ve test edilmesini incelemiştir [18]. Olivier ve arkadaşları, yazılım tanımlı ağ (SDN) tabanlı güvenlik mimarisinin IoT için nasıl daha esnek ve verimli olabileceğini araştırmıştır [19]. Yan ve arkadaşları, IoT hizmetleri ve uygulamaları için güven yönetiminin önemini vurgularken, güven yönetimi konusundaki farklı konuları ve bu konunun IoT geliştiricileri ve kullanıcıları açısından önemini tartışmıştır [20].

## 3. Materyal ve Yöntem

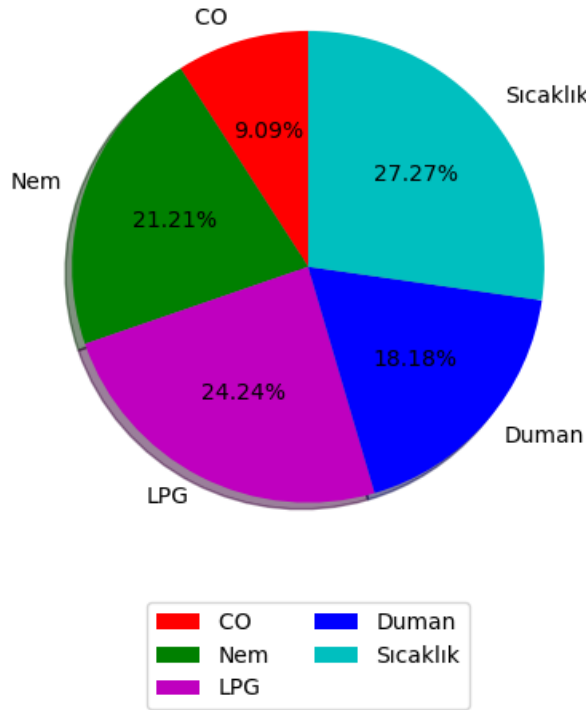
Günümüzde, boğulma ve yangın gibi acil durumlarla başa çıkmak için gelişmiş teknolojilere olan ihtiyaç artmaktadır. Bu amaçla, geniş bir veri seti kullanılarak makine öğrenme algoritmalarıyla risk tahmini yapılması oldukça önemlidir. İncelediğimiz veri setinde bulunan sıcaklık, nem, karbon monoksit (CO), sıvı petrol gazı (LPG), duman, ışık ve hareket gibi çeşitli ölçümler, bu tür acil durumları belirlemede kullanılan ana bileşenlerdir.

Metodoloji kapsamında, bu çalışmada, karbon monoksit (CO), duman ile sıvı petrol gazı (LPG) arasındaki ilişkiyi inceleyerek boğulma risklerini tespit etmeye odaklanılmıştır. Benzer şekilde, nem, sıcaklık ve duman arasındaki ilişki analiz edilerek yangın riski değerlendirilmiştir.

### 3.1. Veri Seti

Veriler, özel olarak yapılmış çevresel sensör dizilerinden oluşan bir dizi tarafından üretilmiştir [21]. Her biri, Şekil 1'de gösterildiği gibi, popüler, düşük maliyetli, kredi kartı boyutunda Linux işletim sistemli Raspberry Pi tek kartlı bilgisayara bağlı olan bir sensör dizisine bağlıdır. IoT cihazları, sıcaklık, nem ve diğer çevresel koşullarda değişen fiziksel konumlara göre yerleştirilmiştir.

Her cihaz, MQ135 Hava Kalitesi Sensörü, DHT22/AM2302 Dijital Sıcaklık ve Nem Sensörü, Onyehn IR Piroelektrik Kızılötesi PIR Hareket Sensörü ve Anmbest Işık Yoğunluğu Algılama Fotosensitif Sensör içermektedir. Her Raspberry Pi cihazı, özel bir Python kodu çalıştırmakta ve AWS IoT Device SDK kullanarak AWS ile iletişim kurmaktadır. Bu kod, dört sensörden düzenli aralıklarla toplam yedi farklı ölçümü toplamaktadır: sıcaklık, nem, karbon monoksit (CO), sıvı petrol gazı (LPG), duman, ışık ve hareket. Kod, ISO standardı Mesaj Kuyruğu Telemetri Taşıma Protokolü (MQTT) ağ protokolünü kullanarak, sensör ölçümlerini cihaz kimliği ve zaman damgasıyla birlikte tek bir mesaj olarak AWS'ye yollamıştır. AWS IoT Analytics, IoT verilerinin toplanmasını, hazırlanmasını, depolanmasını, analiz edilmesini ve görselleştirilmesini sağlamaktadır. AWS IoT Analytics Veri Kümesi, standart SQL kullanarak veri analistlerine düzenli ve güncel içgörüler sağlamıştır. Toplanan verilerden karbon monoksit (CO), sıcaklık, duman, sıvı petrol gazı (LPG) ve nem bu çalışmada için seçilmiş ve analiz edilmiştir. Bu verilerin birbirleriyle olan oranları Şekil 1'de gösterilmiştir.




Şekil 1. Verilerin dağılım grafiği.


Bu veriler için çeşitli makine öğrenmesi modelleri geliştirilmiştir. Bu modeller, verilerin anlamlı ilişkilerini ve desenlerini ortaya çıkarmayı amaçlamaktadır. Ortamın duman ve sıvı petrol gazı (LPG) seviyeleri, karbonmonoksit (CO) oranını etkileyebilir ve bu, boğulma riski hakkında önemli bilgiler verebilir. Karbonmonoksit, renksiz ve kokusuz bir gazdır ve yüksek seviyelerde maruz kalındığında ölümcül olabilir. Bu nedenle, CO seviyelerinin izlenmesi ve kontrol edilmesi hayati öneme sahiptir. Bu çalışmada ortamın CO seviyesi,

duman ve sıvı petrol gazı (LPG) seviyelerine göre tahmin edilmiştir. CO verisinin duman ve LPG verisiyle ilişkisi Şekil 2’de gösterilmiştir.

Bu çalışmada, nem, sıcaklık ve duman arasındaki korelasyon kullanılarak yangın riskleri de ayrıca değerlendirilmiştir. Ortamın sıcaklık ve duman seviyeleri, nem oranını etkileyebilir ve bu, yangın riski hakkında önemli bilgiler verebilir. Bu çalışmada ortamın nem seviyesi, sıcaklık ve duman seviyelerine göre tahmin edilmiştir. Duman ve sıcaklığa göre nem verileri Şekil 3’te gösterilmiştir.



Şekil 2. Duman ve LPG’ye göre CO verileri.



Şekil 3. Duman ve sıcaklığa göre nem verileri.

### 3.2. Önerilen Yöntem

Modellerin geliştirilme sürecinde çeşitli makine öğrenimi algoritmaları incelenmiştir. Bu kapsamda, doğrusal regresyon, karar ağaçları ve rastgele orman algoritmaları kullanılarak geliştirilen modeller eğitilmiştir. Doğrusal regresyon algoritması, girdi özellikleri ile hedef değişken arasındaki doğrusal ilişkiyi analiz ederken, karar ağaçları algoritması, veri noktalarını farklı karar düğümleri kullanarak sınıflandırma yapmaktadır. Rastgele orman algoritması ise, birden fazla karar ağacının birleşiminden oluşarak daha yüksek doğruluk ve genelleme kapasitesine göre çalışmaktadır. Bu algoritmalarla geliştirilmiş makine öğrenmesi modelleri, doğruluk, ortalama karesel hata (Mean Squared Error), R kare değeri (R-squared value), ortalama mutlak hata (Mean Absolute Error) ve Karekök Ortalama Kare Hatası (Root Mean Squared Error) gibi ölçütler ile değerlendirilmiştir.

#### 3.2.1. Doğrusal Regresyon

Doğrusal Regresyon, bir veya daha fazla girdi özelliğine dayalı olarak sürekli bir hedef değişkenini tahmin etmek için yaygın olarak kullanılan bir denetimli öğrenme algoritmasıdır. Bu algoritma, girdi özellikleri ile hedef değişken arasında doğrusal bir ilişki olduğunu varsaymaktadır. Özellikle nicel verilerin analizi ve tahmininde yaygın olarak kullanılmaktadır.

#### 3.2.2. Karar Ağaçları

Karar Ağaçları, girdi özelliklerinin değerlerine dayanarak özellik uzayını bölen ve veri sınıflandırma veya regresyon görevlerini gerçekleştiren denetimli öğrenme algoritmalarıdır. Bu algoritma, girdi özellikleri hakkında bir dizi soru sorarak ve her soruya verilen yanıtı göre veri kümesini alt gruplara ayırarak çalışmaktadır. Karar ağaçları, dallar ve yapraklar şeklinde yapılandırılmıştır; her dal bir özellik veya özellik değeri ile ilgili bir kararı temsil ederken, yapraklar nihai sınıflandırma veya regresyon sonuçlarını temsil eder. Bu algoritma, özellikle yorumlanabilir ve görselleştirilebilir olmasıyla dikkat çeker ve veri içindeki ilişkileri ve desenleri keşfetmek için yaygın olarak kullanılır.

#### 3.2.3. Rastgele Orman

Rastgele Orman (Random Forest), birden fazla karar ağacının birleşimi ile oluşturulan, güçlü ve esnek bir denetimli öğrenme algoritmasıdır. Bu yöntem, her bir ağacın bağımsız olarak eğitildiği ve sınıflandırma veya regresyon görevleri için oy çokluğu veya ortalama ile sonuçların belirlendiği bir ansambl öğrenme tekniğidir. Rastgele Orman, özellikle aşırı uyum riskini azaltması ve yüksek doğruluk sağlaması nedeniyle tercih edilmektedir. Her bir ağaç, veri setinin farklı bir alt kümesi ve özelliklerin rastgele bir alt kümesi kullanılarak eğitildiğinden, modelin genelleme yeteneği artar ve veri içindeki karmaşık ilişkileri ve desenleri daha iyi keşfeder.

### 4. Deneysel Sonuçlar

Makine öğrenmesi algoritmasıyla geliştirilen modeller, sensörlerden elde edilen sıcaklık, nem, karbon monoksit (CO), sıvı petrol gazı (LPG) ve duman özelliklerine dayalı olarak boğulma ve yangın risklerinin analizleri için kullanılacaktır. Tablo 1'de, boğulma ve yangın risklerini tahmin etmek için üç farklı makine öğrenmesi modelinin (Doğrusal Regresyon, Karar Ağaçları, Rastgele Orman) performansları karşılaştırılmaktadır. Boğulma riski modelleri için tüm algoritmalar oldukça yüksek doğruluk oranları göstermektedir. Yangın riski tahmini için Karar Ağaçları ve Rastgele Orman algoritmalarının doğruluğu daha yüksektir. Doğrusal Regresyon modeli yangın riskini tahmin etmekte diğer algoritmalara göre daha düşük bir doğruluk sergilemiştir. Bu nedenle yangın riskini tahmin etmek için daha karmaşık modellerin kullanılması gerektiği görülmektedir. Sonuçlar incelendiğinde, boğulma riski modelleri ve yangın riski modelleri arasında Karar Ağaçları algoritmasının eğitim ve test doğruluğunun daha yüksek olduğu görülmektedir.

En iyi sonucu veren Karar Ağaçları modelinin performansını daha iyi değerlendirmek amacıyla ortalama karesel hata (Mean Squared Error), R kare değeri (R-squared value), ortalama mutlak hata (Mean Absolute Error) ve Karekök Ortalama Kare Hatası (Root Mean Squared Error) ölçütleri hesaplanmış ve bu değerler Tablo 2'de sunulmuştur. Bu tabloda gösterildiği üzere, boğulma riski modeli için hata değerleri oldukça düşük olup,  $R^2$  değeri 0,9999 gibi yüksek bir seviyededir. Bu da modelin boğulma riskini tahmin etmede oldukça başarılı olduğunu göstermektedir. Yangın riski modeli için ise  $R^2$  değeri 0,92 olup, boğulma riski modeline kıyasla biraz daha düşük

bir doğruluk göstermektedir. Ancak, hata oranları çok yüksek seviyede olmadığı için bu model de güvenilir bir tahmin performansı sergilemektedir.


**Tablo 1.** Modeller için eğitim ve test doğrulukları karşılaştırması.

Modeller	BOĞULMA RİSKİ SONUÇLARI		YANGIN RİSKİ SONUÇLARI	
	Eğitim doğruluğu	Test doğruluğu	Eğitim doğruluğu	Test doğruluğu
Doğrusal regresyon	0,999983885838265	0,999984109115112	0,5534698031705984	0,55619564681251
Karar ağaçları	0,999999999796625	0,999998227958908	0,9422338602458314	0,9239682135531241
Rastgele orman	0,999997508156356	0,99999819997838	0,9414072173047445	0,9270064488316794

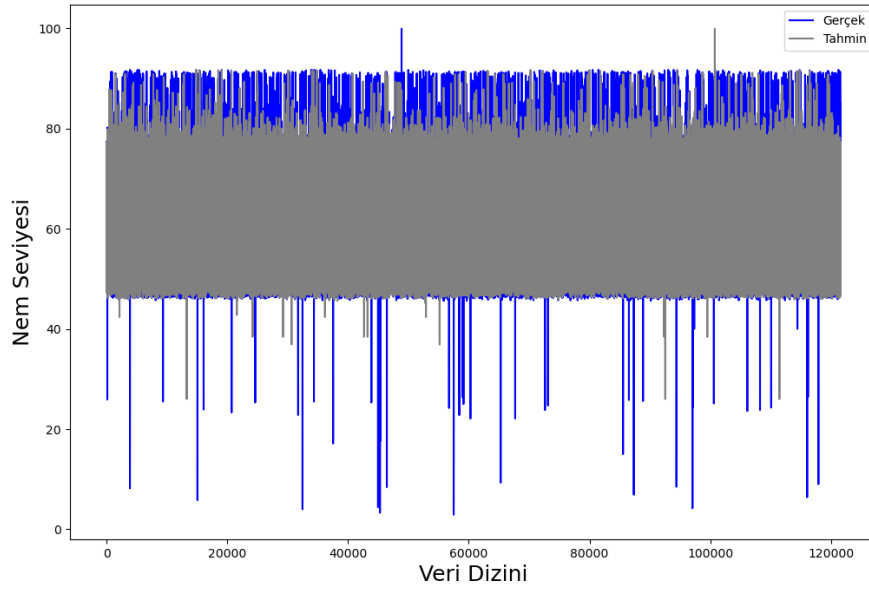
**Tablo 2.** Karar ağacı modelinin değerlendirilmesi.

MODEL ÖLÇÜTLERİ	BOĞULMA RİSKİ MODELİ	YANGIN RİSKİ MODELİ
Ortalama karesel hata	2,7593929502003615e-13	9,781734509621513
R kare değeri	0,9999998227958908	0,9239682135531241
Ortalama mutlak hata	7,402135064247846e-09	1,419058710982499
Karekök Ortalama Kare Hatası	5,25299243308075e-07	3,1275764594365256

Nem seviyesinin doğru tahmini, sıcaklık ve duman verileriyle birlikte değerlendirildiğinde, yangın riskinin önceden belirlenmesine olanak sağlayacaktır. Geliştirilen Karar Ağaçları modeli, CO seviyesi tahmini ile boğulma riskinin, nem seviyesi tahmini ile ise yangın riskinin analizinde kullanılabilir. Karar Ağaçları modelinin CO seviyesi ve nem seviyesi için gerçek ve tahmin değerlerinin grafiksel dağılımları çıkarılmış ve Şekil 4 ve 5'te gösterilmiştir. Şekil 4, Karar Ağaçları algoritmasıyla tahmin edilen CO seviyeleri ile gerçek CO seviyelerinin dağılımını göstermektedir. Grafikte mavi renk gerçek değerleri, gri renk ise tahmin edilen değerleri temsil etmektedir. Modelin tahmin ettiği değerler, gerçek değerlerle büyük ölçüde örtüşmektedir. Bu durum, geliştirilen makine öğrenmesi modelinin CO seviyesini başarılı bir şekilde tahmin edebildiğini ve boğulma risk analizinde güvenilir bir araç olarak kullanılabileceğini göstermektedir. Şekil 5'te ise, Karar Ağaçları algoritması ile tahmin edilen nem seviyeleri ile gerçek nem seviyelerinin karşılaştırması sunulmaktadır. Bu şekilde de mavi renk gerçek nem seviyelerini, gri renk ise modelin tahmin ettiği değerleri göstermektedir. Şekil 5'te görüldüğü üzere, tahmin edilen değerlerin gerçek değerlerle büyük ölçüde örtüşmesi, modelin yangın riski analizinde güvenilir sonuçlar üretebildiğini ortaya koymaktadır.



**Şekil 4.** Boğulma riski tahmin sistemleri için karar ağaçları modelinin CO seviyesinin gerçek ve tahmin değerleri.



**Şekil 5.** Yangın riski tahmin sistemleri için karar ağaçları modelinin nem seviyesinin gerçek ve tahmin değerleri.

## 5. Sonuç

Bu çalışma, makine öğrenmesi tekniklerini kullanarak boğulma ve yangın risklerini tahmin etmeye yönelik bir yaklaşım sunmuştur. Bu çalışma kapsamında, boğulma ve yangın risklerini önceden tespit edebilmek için çeşitli makine öğrenmesi algoritmaları incelenmiş ve uygulanmıştır. Veri setinden seçilen nem ve sıvı petrol gazı (LPG) seviyelerine göre karbon monoksit (CO) seviyesi tahmini; sıcaklık ve duman seviyelerine göre nem seviyesi tahmini oluşabilecek boğulma ve yangın risklerinin tahmininde yardımcı olacaktır. Bu veriler, özel olarak geliştirilmiş sensör dizileri tarafından toplanmış ve makine öğrenmesi yöntemleriyle analiz edilmiştir. IoT tabanlı sensörlerden elde edilen verilerle eğitilen modeller, deneysel sonuçlarla değerlendirilmiş ve doğruluk oranları karşılaştırılmıştır. Çalışmanın temel bulgularına göre, boğulma riski tahmini için en iyi performans Karar Ağaçları modeli göstermiştir ve %99,99 gibi çok yüksek bir doğruluk oranına ulaşmıştır. Bu durum, modelin CO seviyelerini ve ilgili değişkenleri oldukça başarılı bir şekilde tahmin ettiğini ortaya koymaktadır. Yangın riski tahmini için Karar Ağaçları ve Rastgele Orman algoritmaları yaklaşık %92 doğruluk oranıyla benzer sonuçlar vermiştir. Bu oran, modelin yangın riskini makul bir doğrulukla öngörebildiğini göstermektedir. Ancak, doğrusal regresyon modelinin düşük performansı, yangın tahmini için doğrusal olmayan yaklaşımların daha etkili olduğunu göstermektedir.

Hata analizleri incelendiğinde, Karar Ağaçları algoritmasının ortalama karesel hata (MSE) ve  $R^2$  metriği açısından güçlü bir performans sergilediği görülmüştür. Özellikle boğulma riski tahmininde  $R^2$  değerinin 0,9999 olması, modelin değişkenler arasındaki ilişkileri oldukça iyi öğrendiğini göstermektedir. Deneysel sonuçlarda, modelin tahmin ettiği değerlerin gerçek ölçüm değerleriyle büyük ölçüde örtüştüğü görülmektedir. Bu durum, Karar Ağaçları modelinin CO seviyeleri ve nem seviyeleri için güvenilir tahminler yapabildiğini ve bu sayede boğulma ve yangın risk analizlerinde etkin bir araç olarak kullanılabileceğini kanıtlamaktadır.

Bu çalışma, yangın ve boğulma risklerini tahmin etmek amacıyla IoT destekli, makine öğrenmesi tabanlı bir sistem sunarak, acil durum yönetimi alanında uygun yaklaşımların geliştirilmesine katkı sağlayacaktır. Modelin erken uyarı sistemleriyle entegre edilmesi, özellikle endüstriyel alanlar, akıllı binalar ve kapalı ortamlarda risk yönetimini geliştirecektir. Gerçek zamanlı uygulamalar için geliştirilen sistem, yangın ve boğulma vakalarına hızlı müdahale edilmesini sağlayarak can ve mal kayıplarını en aza indirmeye yardımcı olabilir.

Bu çalışma, makine öğrenmesi ve IoT teknolojilerini birleştirerek akıllı risk yönetimi sistemleri için önemli bir adım sunmaktadır. Bu çalışma için geliştirilen model, gelecekte daha karmaşık sistemlere entegre edilerek, çevresel güvenlik çözümlerine katkı sağlayabilir. Çalışmanın bulgularına dayanarak, gelecekte daha geniş ve çeşitli veri setleri kullanılarak modelin farklı çevresel koşullardaki başarısının test edilmesi, derin öğrenme modellerinin entegrasyonu ile daha yüksek doğruluk oranlarına ulaşılması, gerçek zamanlı IoT sistemleriyle saha

testlerinin gerçekleştirilmesi ve farklı sensör teknolojilerinin eklenmesiyle modelin daha geniş ölçekli uygulanabilirliğinin artırılması önerilmektedir.

### Kaynaklar

- [1] Shaikh M, Ali A, Ahmed R, Shaikh BA. A review on Internet of Things (IoT) based water monitoring system. *J Kejuruter* 2023; 35(6): 1273-1278.
- [2] AlZubi AA. IoT-based automated water pollution treatment using machine learning classifiers. *Environ Technol* 2024; 45(12): 2299-2307.
- [3] Kaginalkar A, Kumar S, Gargava P, Niyogi D. Review of urban computing in air quality management as smart city service: An integrated IoT, AI, and cloud technology perspective. *Urban Clim* 2021; 39: 100972.
- [4] Vo DT, Nguyen XP, Nguyen TD, Hidayat R, Huynh TT, Nguyen DT. A review on the internet of thing (IoT) technologies in controlling ocean environment. *Energy Sources Part A: Recovery Util Environ Eff* 2021; 43(1): 1-19.
- [5] Popescu SM, Mansoor S, Wani OA, Kumar SS, Sharma V, Sharma A, Arya VM, ve diğerleri. Artificial intelligence and IoT driven technologies for environmental pollution monitoring and management. *Front Environ Sci* 2024; 12: 1336088.
- [6] Khalil K, Elgazzar K, Seliem M, Bayoumi M. Resource discovery techniques in the internet of things: A review. *Internet Things* 2020; 12: 100293.
- [7] Al-Obaidi KM, Hossain M, Alduais NAM, Al-Duais HS, Omrany H, Ghaffarianhoseini A. A review of using IoT for energy efficient buildings and cities: A built environment perspective. *Energies* 2022; 15(16): 5991.
- [8] Musa AA, Hussaini A, Qian C, Guo Y, Yu W. Open radio access networks for smart IoT systems: State of art and future directions. *Futur Internet* 2023; 15(12): 380.
- [9] Li Y, Alqahtani A, Solaiman E, Perera C, Jayaraman PP, Buyya R, Morgan G, Ranjan R. IoT-CANE: A unified knowledge management system for data-centric Internet of Things application systems. *J Parallel Distrib Comput* 2019; 131: 161-172.
- [10] Xiang J, Zhao A, Tian GY, Woo W, Liu L, Li H. Prospective RFID sensors for the IoT healthcare system. *J Sensors* 2022; 2022(1): 8787275.
- [11] Abdulmalek S, Nasir A, Jabbar WA, Almuahy MAM, Bairagi AK, Khan MA-M, Kee S-H. IoT-based healthcare-monitoring system towards improving quality of life: A review. *Healthcare* 2022; 10(10): 1993.
- [12] Al-Rawashdeh M, Keikhosrokiani P, Belaton B, Alawida M, Zwiri A. IoT adoption and application for smart healthcare: A systematic review. *Sensors* 2022; 22(14): 5377.
- [13] Hintaw AJ, Manickam S, Aboalmaal MF, Karuppayah S. MQTT vulnerabilities, attack vectors and solutions in the Internet of Things (IoT). *IETE J Res* 2023; 69(6): 3368-3397.
- [14] Sharma A, Nayyar A, Singh KJ, Kapoor DS, Thakur K, Mahajan S. An IoT-based forest fire detection system: design and testing. *Multimed Tools Appl* 2023; 83(13): 38685-38710.
- [15] Riskiawan HY, Gupta N, Setyohadi DPS, Anwar S, Kurniasari AA, Hariono B, Firmansyah MH, Yogiswara Y, ve diğerleri. Artificial intelligence enabled smart monitoring and controlling of IoT-green house. *Arab J Sci Eng* 2023; 49(3): 3043-3061.
- [16] Prabu RT, Sarkar M, Chaudhary D, Al Obaid S, Al-ateeq TK, Kalam MA. IoT-enabled groundwater monitoring with k-NN-SVM algorithm for sustainable water management. *Acta Geophys* 2024; 72(4): 2715-2728.
- [17] Yan Z, Zhang P, Vasilakos AV. A survey on trust management for Internet of Things. *J Netw Comput Appl* 2014; 42: 120-134.
- [18] Olivier F, Carlos G, Florent N. New security architecture for IoT network. *Procedia Comput Sci* 2015; 52: 1028-1033.
- [19] Azzedin F, Alhazmi T. Secure data distribution architecture in IoT using MQTT. *Appl Sci* 2023; 13(4): 2515.
- [20] Vo DT, Nguyen XP, Nguyen TD, Hidayat R, Huynh TT, Nguyen DT. A review on the internet of thing (IoT) technologies in controlling ocean environment. *Energy Sources Part A: Recovery Util Environ Eff* 2021; 43(1): 1-19.
- [21] Stafford G. Environmental Sensor Telemetry Data - Kaggle. Erişim: 04 Mart 2025. [Çevrimiçi]. Erişim adresi: <https://www.kaggle.com/datasets/garystafford/environmental-sensor-data-132k/code>