

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİK PANO YANGINLARINA KARŞI NESNELERİN
İNTERNETİ DESTEKLİ ALGILAMA SİSTEMİNİN
GELİŞTİRİLMESİ**

DOKTORA TEZİ

Muhammed Fatih PEKŞEN

Yangın ve Yangın Güvenliği Anabilim Dalı

MAYIS 2024

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİK PANO YANGINLARINA KARŞI NESNELERİN
İNTERNETİ DESTEKLİ ALGILAMA SİSTEMİNİN
GELİŞTİRİLMESİ**

DOKTORA TEZİ

Muhammed Fatih PEKŞEN

Yangın ve Yangın Güvenliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Yılmaz UYAROĞLU

MAYIS 2024

Muhammed Fatih PEKŞEN tarafından hazırlanan “Elektrik Pano Yangınlarına Karşı Nesnelerin İnterneti Destekli Algılama Sisteminin Geliştirilmesi” adlı tez çalışması 20.05.2024 tarihinde aşağıdaki jüri tarafından oy birliği/~~oy çokluğu~~ ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Yangın ve Yangın Güvenliği Anabilim Dalı Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. Hakan Serhad SOYHAN Sakarya Üniversitesi	
Jüri Üyesi :	Prof. Dr. Yılmaz UYAROĞLU (Danışman) Sakarya Üniversitesi	
Jüri Üyesi :	Prof. Dr. Hüseyin ALTUNDAĞ Sakarya Üniversitesi	
Jüri Üyesi :	Prof. Dr. Cenk ÇELİK Kocaeli Üniversitesi	
Jüri Üyesi :	Prof. Dr. Fehim FINDIK SakaryaUygulamalı Bilimler Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “ELEKTRİK PANO YANGINLARINA KARŞI NESNELERİN İNTERNETİ DESTEKLİ ALGILAMA SİSTEMİNİN GELİŞTİRİLMESİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(20/05/2024)

Muhammed Fatih PEKŞEN





Değerli aile büyüklerime, eşime ve çocuklarıma



TEŞEKKÜR

Bu çalışmam sırasında ve hayatımın her döneminde bana sabırla destek olan, başarıya ulaşmam için gerekli motivasyonu sağlayan değerli aile büyüklerime ve bu akademik yolculuğumda, bilgi ve deneyimlerini benimle paylaşarak akademik gelişimime katkıda bulunan değerli tez danışmanıma ve değerli hocalarıma minnettarlığımı ifade etmek isterim. Onların rehberliği, bu çalışmanın şekillenmesinde ve akademik hedeflerime ulaşmamda büyük bir rol oynamıştır. Ayrıca, bana her zaman güvenen ve destek olan tüm çalışma arkadaşlarıma ve dostlarıma teşekkür ederim. Onların varlığı, bu akademik serüvenim boyunca bana güç vermiştir.

Son olarak, bu çalışmanın her aşamasında yanımda olan ve sürekli desteğini esirgemeyen aileme özel bir teşekkürü borç bilirim. Onların sevgisi, sabrı ve anlayışı olmasaydı, bu çalışmanın tamamlanması mümkün olmayabilirdi. Onlara olan minnettarlığımı ifade etmek için kelimeler yetersiz kalır.

Hepinize içtenlikle en derin saygılarımı sunarım.

Muhammed Fatih PEKŞEN



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Tezin Kapsamı	8
1.2. Tezin amacı	8
1.3. Hipotez	9
2. LİTERATÜR TARAMASI	11
2.1. Yanma Nedir	11
2.2. Dedektörler	16
2.2.1. Isı dedektörleri	16
2.2.2. Alev dedektörleri	16
2.2.3. Gaz dedektörleri	17
2.2.4. Lineer detektör	18
2.2.5. Termal kameralar	18
2.3. Elektrik panosu ve türleri	20
2.4. Elektrik panolarında kullanılan elemanlar	21
2.5. Elektrik Kablolarında Kullanılan İzolasyon Çeşitleri	23
2.6. Ticari ve endüstriyel tesislerde yangın algılama stratejileri	26
2.7. Elektrik panosu yangın sebepleri	26
2.8. Elektrik panolarında veri analitiği kullanarak yangın riskinin tahmini	28
2.9. Nesnelerin İnterneti	28
2.9.1. Elektrik panolarındaki yangın algılama sistemlerinin uzaktan izlenmesi	29
2.10. Makine Öğrenimi	30
2.10.1. Karar Ağaçları Algoritması	35
2.10.2. Destek vektör makinesi algoritması	36
2.10.3. Gauss naive bayes sınıflandırıcı algoritması	37
2.10.4. Gauss süreç sınıflandırıcısı algoritması	38
2.10.5. Rastgele Orman Algoritması	39
2.10.6. Lojistik regresyon sınıflandırma algoritması	40
2.10.7. İkili lojistik regresyon sınıflandırma algoritması	40
2.10.8. Sinir ağları algoritması	41
2.10.9. K-En Yakın komşu algoritması	41
2.10.10. Makine öğreniminde doğrulama teknikleri	44
2.10.10.1. K-katlı çapraz doğrulama	44

2.10.10.2. Sınama Kümesi Doğrulama	45
2.10.10.3. Bir veri noktasını dışarda bırakma çapraz doğrulama.....	46
2.10.10.4. Önyüklemeli çapraz doğrulama	47
2.10.11. Makine Öğreniminde İstatistiksel Analiz.....	49
2.10.11.1. Minimum artıklık maksimum ilgililik (MAMI).....	49
2.10.11.2. Ki-Kare testi	50
2.10.11.3. Varyans analizi (ANOVA) testi	50
2.10.11.4. Kruskal Wallis testi	51
2.10.11.5. Makine öğrenimi (ML) uygulamaları	53
2.10.11.6. Veri toplama	53
2.10.11.7. Özellik seçimi.....	53
2.10.11.8. Özellik eleme.....	54
3. MATERYAL VE METOT	59
3.1. Arduino.....	62
3.2. Sensörler	65
3.2.1. MQ-4 Gaz ölçüm modülü	65
3.2.2. MQ-135 Hava Kalitesi Algılama	65
3.2.3. DHT22 Nem ve Sıcaklık Algılama	66
3.2.4. PZEM-004T-100A Güç Volt Akım Test Modülü.....	66
3.3. Raspberry Pi	68
3.3.1. IR Kamera	69
3.4. Deney Kablosu	73
3.5. Kondansatör.....	76
3.6. Deney Prosedürü	77
3.7. Deney verilerinin Nesnelerin İnterneti (IoT) ile ThingSpeak Bulut sistemine aktarılması	79
3.8. Ana makinede verileri işleme	81
3.9. Deney verileri	85
4. DENEY VERİLERİNİN MAKİNE ÖĞRENİMİ (ML) METODU İLE İŞLENMESİ VE PERFORMANS DEĞERLENDİRME.....	95
5. SONUÇLAR VE DEĞERLENDİRME.....	109
KAYNAKLAR.....	111
ÖZGEÇMİŞ.....	135

KISALTMALAR

ANOVA	: Varyans analizi
BYKHY	: Binaların Yangında Korunması Hakkında Yönetmelik
CO	: Karbonmonoksit
CO₂	: Karbon dioksit
EGO	: Entegre geliştirme ortamı
EPR	: Etilen propilen kauçuğu
GNB	: Gauss naive bayes
GPC	: Gauss süreç sınıflandırıcısı (Gauss process classifier)
IoT	: Nesnelerin interneti (Internet of Things)
IR	: Kızıl ötesi (Infrared)
İLR	: İkili lojistik regresyon
LR	: Lojistik regresyon
KA	: Karar ağacı
KNN	: K-En yakın komşu
ML	: Makine öğrenmesi (Machine Learning)
MAMİ	: Minimum artıklık maksimum ilgililik
RA	: Rastgele orman algoritması
PVC	: Polvinil klorür
RA	: Rastgele orman algoritması
SEBS	: Stiren Etilen Butilen Stiren
SVM	: Destek vektör makinesi (Support Vector Machine)
TPE	: Termoplastik plastomer
TPO	: Termoplastik poliolefin
TPU	: Termoplastik poliüretan
UV	: Mor ötesi (Ultraviolet)
XLPE	: Çapraz bağlı polietilen



SİMGELER

Σ	: Toplam simgesi
A	: Amper [A]
$^{\circ}\text{C}$	: Santigrat derece [santigrat]
GB	: gigabayt [bayt]
kB	: kilobayt [bayt]
kvar	: Kilovolt amper reaktif [kvar]
MHz	: Mega hertz [hertz]
ppm	: Milyonda bir birim [ppm]
N	: Normal
S1	: Isı salınım grafiği, yanma başlama aşaması, Sınıf1
S2	: Isı salınım grafiği, yanma gelişme aşaması, Sınıf2
S3	: Isı salınım grafiği, tam yanma aşaması, Sınıf3
S4	: Isı salınım grafiği, yanmanın sönme aşaması, Sınıf4
V	: Volt [v]



TABLO LİSTESİ

Sayfa

Tablo 2.1. Yangın algılayıcı tipleri, özellikler ve kullanım alanları	19
Tablo 2.2. Pano içi elektriksel elemanları	22
Tablo 2.3. Elektriksel kablo özellikleri ve izolasyon çeşitlerini	25
Tablo 2.4. Denetimli öğrenme uygulama türleri ve algoritmaları.....	32
Tablo 2.5. Denetimsiz öğrenme uygulama türleri ve algoritmaları.	33
Tablo 2.6. Makine Öğrenimi (ML) Türlerinin Karşılaştırması	34
Tablo 2.7. Sınıflandırma Algoritmalarının Karşılaştırması.....	42
Tablo 2.8. Doğrulama Tekniklerinin Karşılaştırması.....	48
Tablo 2.9. İstatistiksel testlerin karşılaştırılması.	52
Tablo 2.10. Özellik eleme metotlarının karşılaştırılması	56
Tablo 3.1. Gömülü Sistem ve Geliştirme Platformlarının Özellik Karşılaştırması...	61
Tablo 3.2. Arduino mikrodenetleyicileri modellerinin teknik özellik karşılaştırması	63
Tablo 3.3. Arduino Mega ve Raspberry Pi 4 karşılaştırma	72
Tablo 3.4. Deneyde kullanılan normal ve modifiye edilmiş kablolar.	76
Tablo 3.5. Termal ve NOIR Kamera Görüntülerinin Dosya Boyutları ile Günlük ve Yıllık Depolama İhtiyaçlarının Hesaplanması.....	85
Tablo 3.6 Deney aşamalarına göre Arduino Mega ve Raspberry Pi 4 verilerinin değerleri.....	86
Tablo 3.7. Arduino Mega ve Raspberry Pi örnek veriler	87
Tablo 3.8. 5kvar beyaz kablo deneyi verileri.	88
Tablo 3.9. 2,5kvar, 7 tel eksiltilmiş beyaz kablo deneyi verileri.....	91
Tablo 4.1. İki sınıflı sınıflandırma için karışıklık matrisi	99
Tablo 4.2. Model doğruluk (validasyon) oranları.	100
Tablo 4.3. Modellerin eğitim sonrası karışıklık matrisleri.	100
Tablo 4.4. Model test sonrası doğruluk oranları.....	102
Tablo 4.5. Modellerin test sonrası karışıklık matrisleri.....	103
Tablo 4.6. İnce karar ağacı, İkili lojistik regresyon, Gaussian Naive Bayes, Gaussian SVM ve K-En yakın komşu algoritmalarının karşılaştırmalı alıcı işletim karakteristik eğrisi ve eğri altında kalan alan analizi grafikleri.	105
Tablo 5.1. Modellerin doğruluk oranları (eğitim (validasyon) ve test).....	109



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Elektrik pano yangın örnekleri. (a) sayaç panosunda yaşanmış olan bir yangın (Kocaeli ili, Çayırova ilçesi, 23 Mayıs 2019). (b) Elektrik güç dağıtım panosunda yaşanmış bir yangın (Batman ili, 21 Şubat 2020). (c) Elektrik kompanzasyon panosunda yaşanmış bir yangın. (d) Elektrik güç dağıtım panosunda yaşanmış bir yangın (Yalova ili, İstanbul Caddesi, 11.09.2019).	3
Şekil 2.1. (a)Yangın üçgeni, (b)parlama dörtgeni, (c)patlama beşgeni (OSHA 3644-04, 2013).	12
Şekil 2.2. Yeni nesil akıllı algılayıcılar (Lv, L. Y., ve ark. 2022)	13
Şekil 2.3. Isı dedektörü	16
Şekil 2.4. Alev dedektörü.....	17
Şekil 2.5. Gaz dedektörü.....	17
Şekil 2.6. Lineer detektör yapısı	18
Şekil 2.7. (a)Termal kamera (b) görüntülenen ortam (c) termal görüntü	18
Şekil 2.8. Isı salınım grafiği. (Alarifi, A. A. S.,ve ark. 2016).....	28
Şekil 2.9. Makine öğrenimi (ML) yöntemleri (Xu, Z., & Saleh, J. H., 2021).	31
Şekil 2.10. Karar ağaçları örnek gösterimi (Kaur, S., ve ark. 2023)......	35
Şekil 2.11. Rastgele orman algoritması örnek gösterimi (Lakshmanaprabu, S. K., ve ark. 2019)	39
Şekil 2.12. Veri kümesinin eğitim ve test alt kümelerinde bölünmesi ve K-Katlı çapraz doğrulamanın gerçekleştirilmesi	45
Şekil 2.13. Veri kümesinin eğitim ve test alt kümelerinde bölünmesi ve sına kümesi doğrulamanın gerçekleştirilmesi.	46
Şekil 2.14. Veri kümesinin eğitim ve test alt kümelerinde bölünmesi ve veri noktasını dışarda bırakma çapraz doğrulama.....	47
Şekil 2.15. Önyüklemeli çapraz doğrulama	48
Şekil 3.1. Deney amaçlı yaptırılan elektrik panosu a) Arduino Mega b) Raspberry Pi 4 c) Deney kablosu d) Kondansatör.	60
Şekil 3.2. Arduino ile problemin tanımlanması ve prototip geliştirme süreci (Kondaveeti, H. K., ve ark. 2021).	62
Şekil 3.3. Arduino Mega yangın algılama sistemi sinyal işleme şeması.	64
Şekil 3.4. Arduino mikro kontrol sistemi (a) Com4 portu iletişim ekranı (b) veri akışı (c) derleyici program ile geliştirilen kodlama ekranı.	66
Şekil 3.5. Arduino kod bloğu algoritma akış diyagramı.	67
Şekil 3.6. Raspberry Pi 4 yangın algılama sistemi sinyal işleme şeması.....	69
Şekil 3.7. Kontaktör ile kondansatör arasındaki kablonun kızılötesi termal kamera görüntü örnekleri.	71
Şekil 3.8. Thonny Python derleyici IR kamera kodlama ekranı	71
Şekil 3.9. Panoda kullanılan orijinal siyah renkli kablo.	74

Şekil 3.10. a) mavi kablo, b) mavi kıl sayısı azaltılmış kablo, c) mavi ezilmiş (ezik bölge kırmızı alan içerisinde) kablo, d) mavi izolasyonunda kesikler oluşturulmuş kablo, e) 3 kat beyaz kablo, f) 2 kat beyaz kablo.	74
Şekil 3.11. a) siyah kablo, b) siyah kıl sayısı azaltılmış kablo, c) siyah ezilmiş (ezik bölge kırmızı alan içerisinde) kablo d) siyah izolasyonunda kesikler oluşturulmuş kablo, e) 3 kat beyaz kablo, f) 2 kat beyaz kablo, g) ince kablo.	75
Şekil 3.12. Deneylerde kullanılan a) 2.5kvar kondansatör, b) 5kvar kondansatör. ...	77
Şekil 3.13. Blok diyagram şeması.....	79
Şekil 3.14. Nesnelerin interneti (IoT) altyapısının ThinkSpeak ile oluşturulması.....	80
Şekil 3.15. Verilerin (a)Arduino Mega ile Esp8266 WiFi modülü, (b)Raspberr Pi ve WiFi özelliği kullanılarak ThinkSpeak platformuna gönderilmesi.	81
Şekil 3.16. Matlab appdesigner ekranı ile ThingSpeak üzerindeki verilerin çağırılması.	82
Şekil 3.17. Matlab appdesigner raporlama ekranındaki ilgili satıra ait pano resimlerinin Google Drive üzerinden çağırılması.	83
Şekil 3.18. Matlab uygulama tasarlayıcı ekranı ile tasarlanmış raporlama ekranına ait ilgili resmin görüntü filtreleri.	84
Şekil 3.19. (a) 5kvar beyaz kablo, (b) 2,5 kvar 5 tel eksiltilmiş beyaz kablo, (c) 2,5 kvar 8 tel eksiltilmiş beyaz kablo (d) 2,5 kvar 6 tel eksiltilmiş beyaz kablo.	87
Şekil 3.20. (e) ince kablo, (f) 2,5 kvar 6 tel eksiltilmiş beyaz kablo (deney 2) (g) 2,5 kvar 7 tel eksiltilmiş beyaz kablo	88
Şekil 3.21. 5kvar beyaz kablo deney termal kamera görüntüleri.	89
Şekil 3.22. 5kvar beyaz kablo deneyinden elde edilen NOIR kamera görüntüleri....	89
Şekil 3.23. Deney sırasında yanma ve patlama koşullarını gösteren görüntüler.	90
Şekil 3.24. 2,5kvar 7 tel eksiltilmiş beyaz kablo deney termal kamera görüntüleri. .	91
Şekil 3.25. 2,5kvar 7 tel eksiltilmiş beyaz kablo deney NOIR kamera görüntüleri...	92
Şekil 3.26. 2,5kvar, 7 tel eksiltilmiş beyaz kablo deneyinde meydana gelen yanma koşullarını gösteren görüntüler.....	93
Şekil 4.1. Matlab sınıflandırma öğrenimi.	95
Şekil 4.2. Deney verilerinin Matlab programına yükleme.	96
Şekil 4.3. Veri seçimi yapılması ve içe aktarım ekranı.....	96
Şekil 4.4. Doğrulama tekniği seçim ekranı.	97
Şekil 4.5. Matlab istatistiksel analiz yöntemi seçim ekranı.	98
Şekil 4.6. Matlab programında verilerin eğitilmesi sürecinde kullanılan modeller...	98
Şekil 4.7. Test sonrası modeller.	102

ELEKTRİK PANO YANGINLARINA KARŞI NESNELERİN İNTERNETİ DESTEKLİ ALGILAMA SİSTEMİNİN GELİŞTİRİLMESİ

ÖZET

Bu çalışma, elektrik panolarındaki yangın güvenliği konusuna odaklanmaktadır. Nesnelerin İnterneti (Internet of Things - IoT) ve Makine Öğrenimi (Machine Learning - ML) teknolojilerinin entegrasyonu yoluyla elektrik panolarına yönelik yangın güvenliği önlemlerinin nasıl geliştirilebileceği üzerine çalışılmıştır. Elektrik panolarındaki yangın güvenliği önlemlerinin etkinliğini artırmak amacıyla gerçekleştirilen çalışmalar kapsamlı bir şekilde irdelenmiştir. Araştırma bulguları, yangınların büyük bir kısmının elektrik arızalarından kaynaklandığını ortaya koymuştur. Özellikle gevşek bağlantılar, aşırı yüklenme, izolasyon hataları ve diğer teknik arızalar, yangınların başlıca çıkış noktaları arasında yer almaktadır.

Yangın algılama sistemlerinin gelişimi, yangına dayanıklı malzemelerin kullanımı, düzenli bakım ve denetim prosedürleri, kanunlar, yönetmelikler ve standartlar tarafından kesin sonuçlara bağlanmıştır. Fakat günümüzde hala elektrik panolarında çıkan yangınlar sebepli can kayıplı ve maddi hasarlı birçok vaka yaşanmaktadır. Yeni nesil teknolojiler ve kestirimci bakım yöntemleri, yangın riskini azaltmada öne çıkan stratejilerdir. Kızılötesi tarama ve termal izleme teknikleri, özellikle erken yangın tespiti ve arızalanma risklerini minimize etmede etkili olmaktadır. Bu bağlamda, elektrik panolarında yangın güvenliği üzerine potansiyel iyileştirme alanları tespit edilmiştir. Elektrik panoları yangın güvenliğini artırmak için nesnelerin interneti (IoT) ve makine öğrenmesi (ML) modelleri ile yeni bir yaklaşım üzerinde durulmuş, yangın meydana gelmeden koşulların izlenmesine imkân veren program geliştirilmiştir. Ayrıca, bu program, yapılan deneylerin anlık olarak izlenmesini ve sonuçların raporlanmasını sağlamıştır. Deneylerde Arduino Mega ve Raspberry Pi cihazları verileri toplamıştır. Toplanan veriler pano ortam sıcaklığı, pano ortam nemi, karbonmonoksit, karbondioksit, hidrokarbon gazlarını, voltaj, akım, parametrelerini ve kablo odak sıcaklığı, dış ortam sıcaklığını, dış ortam nemini içermektedir. Çalışmada toplam 21 deney tamamlanmış, 7 deneyde yanma ve yangın meydana gelmiştir. Ayrıca deneylerden 3521 satır x 11 sütun gerçek veri elde edilmiş ve bunlardan 3478 satır ve 9 sütunu ML algoritmalarında kullanılmıştır. Kullanılan ML algoritmaları denetimli öğrenme yönteminden olan, karar ağacı (KA), ikili lojistik regresyon, Gaussian Naive Bayes (GNB), Gaussian Destek Vektör Makinesi (SVM) ve K-En yakın komşu (KNN) yöntemidir. Her bir algoritma 5-katlı çapraz doğrulama yöntemiyle değerlendirilmiştir. Çalışmadan elde edilen, farklı modellerin test performansları şu şekilde ölçülmüştür. Karar ağacı (ince ağaç) modeli %98.7 doğruluk oranı ile yüksek bir performans sergilemiştir. İkili lojistik regresyon modeli %95.3, GNB modeli %91.2 doğruluk oranı ile değerlendirilmiştir. Öte yandan, Gaussian SVM ve KNN yöntemleri her ikisi de %99.3 doğruluk oranı ile en yüksek performansı gösteren modeller olmuştur.

Sonuç olarak, bu tez IoT ve ML teknolojilerinin, elektrik panolarında yangın güvenliğini artırmak ve yangın risklerini azaltmak için yapılmıştır. Geliştirilen

sistemler, endüstriyel tesislerde yangın güvenliđi yönetimini iyileştiren yenilikçi çözümler sunmakta ve yangın öncesi risk değerdendirmeleri yaparak erken müdahale olanaklarını artırmaktadır. Bu bütünleşik yaklaşım, yangın algılama ve müdahale süreçlerinde önemli gelişmelere yol açarak, can ve mal kaybını minimize etmede büyük rol üstlenebilir.



DEVELOPMENT OF AN INTERNET OF THINGS SUPPORTED DETECTION SYSTEM AGAINST ELECTRIC PANEL FIRES

SUMMARY

This study examines how fire safety measures for electrical panels can be enhanced through the integration of Internet of Things (IoT) and Machine Learning (ML) technologies. Electrical panels are known as critical structures in energy transmission, with a high risk of fire due to a variety of electrical faults such as loose connections, overloads, insulation errors, lack of maintenance, and various technical faults. Despite technological advancements in fire detection systems and fire-resistant materials, these panels still pose serious risks in many industrial facilities, occasionally causing material damage and loss of life. A fundamental reason why electrical panels are so risky is that they serve as central nodes of energy systems and are critical points of electrical distribution. Any malfunction in these panels can lead to widespread outages and even major fires. Therefore, reducing the fire risk in these panels, making electrical panels safer, and being able to respond quickly in the event of a fire is of great importance. In this context, the integration of IoT and ML technologies offers a new approach to fire safety by enabling continuous monitoring of electrical panels and conducting risk assessments before a fire occurs. IoT devices can continuously collect data in the panels and transfer this data to a central system. The collected data can be processed by ML algorithms, which can generate alerts in the event of any risk and provide information for preventive maintenance. This allows potential faults to be detected and rectified before they lead to more serious problems.

This advanced technology-based approach enhances the management of electrical panels and connected systems and raises fire safety standards. Such a system not only prevents fires but also reduces maintenance costs and enhances operational efficiency. Therefore, this study thoroughly examines how IoT and ML technologies can be integrated into fire safety solutions for electrical panels and how this integration can minimize fire risks.

The study aims to reduce fire risks and advance fire safety measures in electrical panels using IoT and ML technologies. The developed system aims to detect potential fire hazards in advance and minimize them, providing real-time monitoring and predictive analysis to make electrical panels safer. For this purpose, the design and implementation of an IoT-based sensor network integrated with advanced machine learning algorithms have been adopted. This methodology includes various sensors equipped to monitor critical environmental and electrical parameters using platforms like Arduino Mega and Raspberry Pi. These platforms continuously record parameters directly related to fire, such as temperature, humidity, carbon monoxide, carbon dioxide, and hydrocarbon gases, as well as electrical variables like current, voltage, and frequency changes. Additionally, a thermal camera has been integrated into the system to continuously measure and record the temperature of the cable inside the panel during the experiment. This integration significantly enhances the sensitivity and response time of fire detection and prevention systems.

During the experiments, the collected data were classified based on a heat release graph under four different stages of fire development (S1, S2, S3, S4) and normal (N) conditions. This classification is used to closely monitor and analyze the various stages of a fire from its inception: S1 (non-flaming, pre-ignition conditions), S2 (ignition, flash phase and well flame development), S3 (fully developed fire stage), and S4 (post-fire and decay) conditions. These stages are critical for managing fire risks and developing intervention strategies.

For experimental purposes, an electrical panel was constructed with its front cover cut to specific dimensions and sealed with flexiglass. This allowed the experiment conditions to be monitored and recorded externally via camera. The experiments involved a cable between a contactor and a capacitor, with various cable types used: original cable, cut cable, crushed cable, weakened cable, thin cable, etc. Additionally, the capacitors in the panel were diversified, including 5 kvar and 2.5 kvar capacitors. In summary, experiments were conducted with both 5 kvar and 2.5 kvar capacitors. A total of 21 experiments were conducted, with fires occurring in 7 of them, and real data comprising $3521 \text{ rows} \times 11 \text{ columns}$ (total 38731 data) were collected. Of these, 3478 rows and 9 columns (total 31302) were included in the analysis methods base cluster. The collected data and thermal images are of great importance for the development of fire detection systems and the optimization of fire prevention strategies. Future studies will aim to enhance the accuracy of fire detection algorithms and improve fire response processes using this data. The integrated system in this study reshapes fire safety management in industrial facilities, providing more reliable and effective solutions that minimize loss of life and property.

To process the data obtained from experiments conducted on electrical panels and minimize fire incidents, the academic version of the Matlab program was used. Five different supervised machine learning classification algorithms were selected in Matlab: Decision Trees, Logistic Regression, Gaussian Naive Bayes, Support Vector Machines, and K-Nearest Neighbors. These algorithms were trained on data primarily based on critical features such as carbon monoxide, carbon dioxide, cable temperature, panel interior temperature, and panel humidity, identified through a statistical method called analysis of variance (ANOVA) used for feature selection. ANOVA was used to determine which features provided the most information for fire detection and ultimately led to the decision to use these five features. Each machine learning model was thoroughly tested using a five k-fold cross-validation method, which involves training and testing the model on different parts of the data set to provide a robust evaluation of the model's generalization capability and stability. In five k-fold cross-validation, 80% of the data set was used for training, and the remaining 20% was set aside for testing. Cross-validation measures the performance of each algorithm more objectively and demonstrates the consistency of the algorithm across different data sets.

The results demonstrate that the integration of IoT and ML technologies significantly enhances the capacity to detect and predict potential fire events in electrical panels. Notably, the Support Vector Machines and K-Nearest Neighbor algorithms stood out with extraordinarily high accuracy rates exceeding 99%, underscoring their reliability and effectiveness in fire detection. The decision tree model also exhibited impressive results with an accuracy rate of 98%, demonstrating its ability to model complex data structures. While the logistic regression model showed strong performance with a 95% accuracy rate, the Gaussian Naive Bayes model performed less well, with an accuracy rate of 91%. This indicates that certain algorithms may better suit specific data

structures or feature distributions, and different models may need to be preferred depending on the characteristics of the data set.

The joint integration of IoT and ML technologies in this study offers a new approach to fire safety, not only detecting fire events but also predicting them before they occur. This proactive approach significantly enhances fire safety conditions, especially in high-risk environments such as industrial facilities. The integration of these technologies with traditional fire safety measures transforms fire safety management into a more dynamic and interactive affair, shifting from reactive to proactive and predictive approaches. The use of next-generation technologies allows fire safety systems to play an active role not only during a fire but from the onset of fire risk, enabling real-time collection and analysis of environmental and operational data to identify potentially hazardous abnormal conditions early on. This has great potential to reduce possible damages and especially to protect human life, as well as to identify maintenance needs of panels, which is of great importance not only for safety but also for operational continuity in industrial facilities.

Future studies might also explore the integration of automatic extinguishing mechanisms within the IoT and ML framework, which would enable seamless collaboration between fire detection systems and automatic extinguishing systems, providing a prompt and effective response as soon as a fire occurs. This type of integration would strengthen the capabilities of fire risk management systems further.



1. GİRİŞ

Yangın; herhangi bir zaman diliminde meydana gelebilen, tüm insanlar için büyük bir endişe kaynağı olan, her yıl binlerce kişiyi etkileyerek yaralanmalara ve can kayıplarına sebep veren istenmeyen bir olaydır. Bir yangın geç algılandığı durumda daha büyük yangınlara ve hatta afet boyutunda olayların meydana gelmesine sebep verebilir. 2021 yılı yaz aylarında, ülkemizin Akdeniz bölgesinde orman yangınları meydana gelmiştir. Bu yangınlarda yüksek miktarda mal zararları oluşmuş, istenmeyen can kayıpları yaşanmış ve bölgede yaşayan halk tahliye edilmiştir (Köçer, M. S., ve ark. 2023).

Yangınlar çeşitli sebeplerden meydana gelebilir. Bunlar arasında sigara, kesme-taşlama-kaynaklı imalat çalışmalarında kıvılcım sıçraması, bilinçli yakma, yanıcı gaz veya sıvı parlaması ve elektrik, yangın çıkış sebepleri arasındadır (Kara, İ. B. 2017; Pekşen, M. F., ve ark. 2020).

Elektrik, günümüzde vaz geçilmez bir enerji kaynağı olup, çeşitli alanlarda farklı amaçlar için kullanılmaktadır. Bu amaçlar arasında, aydınlatma ihtiyacının giderilmesi, iklimlendirme şartlarının insana uygun hale getirilmesi, üretimin kesintisiz olarak sürdürülmesi, ulaşım problemlerinin ortadan kaldırılması, sağlık, bilgi ve eğlence sektörlerinde hizmetlerin aksatılmadan sürdürülmesi örnekleri verilebilir. Kısaca, elektrik enerjisi insanlar için hayati öneme sahiptir.

Farklı santral tiplerinde üretilen elektrik enerjisi, iletim hatlarını (şebeke) kullanılarak indirici trafolarla kadar ulaşır. Daha sonra indirici trafodan dağıtım şebekesi yolu ile son kullanıcıya ulaştırılır. Son kullanıcı elde ettiği bu elektrik enerjisini en az bir elektrik panosu yardımı ile işletmesinde veya evinde çeşitli noktalarda kullanabilir. Kullanılan bu panoların işlevi, sadece elektrik enerjisini ilgili yerlere dağıtmak değil, aynı zamanda ölçülebilir, takip edilebilir ve güvenilir kullanımı sağlamaktır. Dolayısıyla panolar enerji dağıtımı için bünyelerinde çeşitli enstrümanlar barındırmaktadır. Bunlar arasında; ana kesiciler, devre kesicileri, sigortalar, kablolar ve bağlantı noktaları gibi çeşitli parçalar yer alır. Bu parçaların yanmaya karşı dirençli olması gerekir. Parçalar ne kadar yanmaya dirençli olsa da çeşitli zamanlarda elektrik

panolarında yangınların meydana geldiği bilinmektedir. Yapılan bir çalışmada pano içerisinde kullanılan iletkenlerin gevşek bağlantısı ve konektörlerin aşırı ısınması sonucunda izolasyonda bozulma meydana geldiği ve yangın çıktığı bilgisi görülmüştür (Huda, A. S. N., ve ark. 2014).

Temelde, bir yanma olayı başlamadan önce ortam ısısında değişim gözlemlenir. Isının beklenmeyen koşullardan dolayı yükselmesi durumunda ortamda bulunan yanıcı madde ve yakıcı madde reaksiyona girer ve yanmayı başlatır. Yanma ve yangın vakalarının meydana gelmemesi, meydana gelirse de en az zararla atlatılmasına için birçok ülkede olduğu gibi ülkemizde de yangınları önleme, yangınlara karşı dayanım ve can güvenliğini sağlama amaçlı mevzuat hazırlanmıştır. Ülkemizde yürürlükte olan bu mevzuat Binaların Yangında Korunması Hakkında Yönetmelik'tir (BYKHY) ve 2007 yılında yürürlüğe girmiştir. Yönetmelik, konutlarda, endüstriyel tesis ve ticari alanlarda yangınlara karşı tedbir alınması için uyum ve sürekli güncellemeyi amaçlayan kesin kurallar koymuştur.

BYKHY incelendiğinde, beşinci kısmın elektrik tesisatı ve sistemleri hakkında bilgiler içerdiği görülmektedir. Bu kısımda yer alan Madde 67 ile Madde 85 arasında “Genel Hükümler”, “İç Tesisat”, “Acil Durum Aydınlatması ve Yönlendirmesi”, “Yangın Algılama ve Uyarı Sistemleri” ve “Periyodik Testler, Bakım ve Denetim” hükümleri açıklanmıştır. Yapılan incelemede elektrik panoları hakkında açıklama görülmemiştir. Elektrik panoları özelinde yanma ve yangın riskini azaltmak, kullanıcı güvenliğini sağlamak ve istenmeyen bir yangın oluşursa bu duruma müdahaleyi kolaylaştırmak amacıyla çeşitli standartların farklı kurumlar tarafından oluşturulduğu görülmüştür. Bunlar arasında en çok bilinir olanlar NFPA 70: Ulusal Elektrik Kuralları, IEC 61439 Elektrik Panoları ve Kontrol Panoları için Standartlar Serisi ve EN 61439 Elektrik Panoları ve Dağıtım Panoları İçin Avrupa Standardıdır.

Özellikle endüstriyel tesislerde elektrik pano yangınları sıklıkla karşılaşılan durumlar arasında yer alabilmektedir. Elektrik panosu, yangınların geç fark edildiği ve yangın söndürülünceye kadar maddi hasarların meydana geldiği birçok habere konu olmuştur. Bu olaylara ait bazı görseller aşağıdaki Şekil 1’de paylaşılmıştır.



(a)



(b)



(c)



(d)

Şekil 1.1. Elektrik pano yangın örnekleri. (a) sayaç panosunda yaşanmış olan bir yangın (Kocaeli ili, Çayırova ilçesi, 23 Mayıs 2019). (b) Elektrik güç dağıtım panosunda yaşanmış bir yangın (Batman ili, 21 Şubat 2020). (c) Elektrik kompanzasyon panosunda yaşanmış bir yangın. (d) Elektrik güç dağıtım panosunda yaşanmış bir yangın (Yalova ili, İstanbul Caddesi, 11.09.2019).

Şekil 1.1. farklı elektrik panolarında meydana gelen yangın olaylarını gözler önüne sermektedir. Bu yangınlara hızlı bir şekilde müdahale edilmiş olmasına karşın, meydana gelen maddi zararlar ve üretim süreçlerine olan etkileri göz ardı edilemeyecek düzeydedir. Sunulan vakalar, herhangi bir elektrik panosunda yangın çıkma ihtimalinin ve bu yangınların neden olabileceği önemli zararların altını çizmektedir. Bu durum, elektrik panolarının yangın güvenliği konusunda ne denli kritik bir rol oynadığını ve bu alanda alınması gereken önlemlerin önemini vurgulamaktadır.

Büyük işletmelerde, tesis büyütme ve makine parkını genişletme çalışmalarında, üretim temposuna yetişmek amacıyla hızlı ve geçici çözümler mevcut elektrik panoları üzerinden enerji alınması şeklinde yürütülmekte ve bazen pano revizyonları ertelenmektedir. Ayrıca endüstri 4.0 koşullarının gelişmesiyle özellikle otomotiv ve gıda fabrikaları gibi büyük endüstriyel tesislerde tam ve yarı otonom sistemlerin kullanımı artmakta, elektrik enerjisine duyulan ihtiyaç fazlalaşmaktadır. Bu ve benzeri

durumlardan dolayı, panolar ilk kurulum şartlarından farklı koşullarda çalıştırılmaktadır. Pano kullanım koşulları standartlara uyum sağlamadığı zaman ve zorlayıcı koşullar altında çalıştırıldığında yangınlara sebep verecektir. Bu konuda geçmiş yıllarda yayımlanmış olan çeşitli raporlar incelendiğinde meydana gelen yangın vakalarının önemli bir oranda elektrik kaynaklı olduğu görülmüştür. Malezya itfaiye ve kurtarma departmanı faaliyet raporunda 2020 yılında meydana gelen yangınların yaklaşık %61'i (4256 olay) elektrik kaynaklı olduğu raporda bildirilmiştir. Benzer şekilde 2021 yılında meydana gelen yangınların yaklaşık %60'ı (4558 olay) elektrik kaynaklı olduğu bildirilmiştir. Ayrıca rapor içerisinde elektrik kaynaklı yangınların yaklaşık %28'i ısınma, %15'i kısa devre, %13'ü ark, %5'i ise aşırı gerilim ve aşırı yük kaynaklı olduğu görülmüştür (Malaysia Fire and Rescue Department, 2021). Diğer bir raporda ise İstanbul Büyükşehir Belediyesi İtfaiye Daire Başkanlığı tarafından 2015-2019 yılları arasında meydana gelen yangınların %23.5'i (29200 olay) elektrik kaynaklı olduğu belirtilmiştir (İstanbul Büyükşehir Belediyesi İtfaiye Daire Başkanlığı, 2020).

Elektrik panolarının doğru çalışması ve yangın riskinin en düşük seviyede tutulması için gerekli revizyonların ve bakımların zamanında yapılması şarttır. BYKHY beşinci kısım, beşinci bölümde “Periyodik Testler, Bakım ve Denetim” ile ilgili hükümler genel olarak açıklanmıştır. Yangın güvenliği ve ekipman denetimi kapsamında tüm elektrikle çalışan aletlerin, elektrik panolarının ve kabloların kontrollerinin yılda en az bir kere bakımdan geçirilmesini ilgili standartlar zorunlu kılmıştır (NFPA 70B, 2016). Fakat yoğun üretim temposu içerisinde kontrol ve bakımlarda olabilecek eksiklik ve aksaklıklar, bakım sonrası ekipmanların hatalı kullanımları, hatta bakımın ertelenmesi gibi durumlar elektrik panolarında yangın çıkmasına sebep verir. Bakımlar için 3 farklı ana yöntem belirlenmiştir ve bunlar iyileştirici, önleyici ve düzeltici bakım yöntemleri olarak ifade edilir (Moblely, R. K., 2011). Önleyici bakımda kendi içerisinde, ekipman odaklı bakım, zaman odaklı bakım ve kestirimci bakım olarak 3 alt grupta yürütülür (Moblely, R. K., 2011).

Bakım çeşitlerinden biri olan kestirimci bakım için ilgililer gerekli verileri yeterli sürede toplar ve sorun tespit edildiğinde makineye müdahaleyi planlar (Scheffer, C., & Girdhar, P., 2004). Bu yöntem toplanan parametrelerin izlenmesine dayalıdır ve üretim durdurulmadan gerçekleştirilir. Dolayısıyla bakımların ertelenmesi veya eksik yapılması gibi insan faktörlü hatalar ortadan kaldırılır. Ayrıca arıza ve yangın

güvenliği açısından birtakım tedbirler önceden alınır. Böylece yangınların neden olabileceği istenmeyen durumlar engellenebilir. Yapılan bir çalışmada, proses bazlı üretim yapan endüstriyel tesislerde en yaygın bakım stratejileri incelenmiş ve maliyet analizleri çıkarılmıştır. Meydana gelen hata sayısının maliyetlere yansımalarına göre optimum verim, kestirimci bakım ile yürütülen süreçlerdedir (Abbassi, R., ve ark. 2022). Başka bir çalışmada ise fotovoltaik sistemlerle elektrik üretimi esnasında anormalliklerin tespiti için kestirimci bakım çalışması yapılmış ve güneş ışıınımı, sıcaklık ve üretilen alternatif akım elektrik gücü verileri yapay sinir ağları yöntemi kullanılarak incelenmiştir (De Benedetti, M., ve ark., 2018). Çalışma sonuçlarında, alternatif akım güç üretim verilerinden elde edilen bilgilerin %90 oranında anormalliği doğru tespit ettiği görülmüştür.

Elektrik ile ilgili frekans, izolasyon, kısa devre ölçümleri, devre kesici (termik-manyetik), transformatör, topraklama muayeneleri, kaçak akım, sigorta, kablo testleri ve kızılötesi denetim incelemeleri kestirimci bakım çalışmalarında kullanılır. Kızılötesi denetim; sağlıkta hastalıkların erken teşhisinde, güvenlikte sınır kontrollerinde ve kaçak geçişlerin tespitinde, arama kurtarma operasyonlarında ve kayıp kişilerin bulunmasında kullanılır (Glowacz, A., 2021).

Kestirimci bakımlarda kullanılan kızılötesi denetim, tahribatsız muayene ile işlemi gerçekleştirdiği için endüstriyel tesislerde sıklıkla tercih edilir. Bu işlem ile elektrik sistemlerinin arızalarını tespit etmede, plansız duruşları ortadan kaldırmada ve elektrik kaynaklı yangın oluşma ihtimalini değerlendirmede kullanılır. Ayrıca kızılötesi denetim temassız ölçümle, düşük maliyet, güvenilir ve etkili olma avantajı sunar (Han, S., 2020). Bu duruma bir örnek olarak Türkiye’de yürürlükte olan İş Ekipmanlarının Kullanımında Sağlık ve güvenlik Şartları Yönetmeliği EK-III, Tablo-3 içerisinde elektrik tesisatı ve topraklama tesisatı periyodik kontrol süresini (Azami süre) 1 yıl olarak belirlemiş fakat yöntem belirtmemiştir (İş Ekipmanlarının Kullanımında Sağlık ve Güvenlik Şartları Yönetmeliği,2013). Elektrik güç dağıtım ekipmanı ve sistemleri için bakım testi spesifikasyonları standardı (ANSI/NETA MTS) NFPA 70B (2019) bölüm 11.17 Kızılötesi İnceleme şu üç durum hakkında değerlendirme yapılması gerektiğini yazılı hale getirmiştir. Bunlar;

Ölçüm değerlerinde normal koşullara göre;

- Sıcaklık farkı 1°C ile 3°C arasında ise olası bir kusur bulunduğunu ve bu durumun araştırılması gerektiğini ifade eder.
- Sıcaklık farkı 4°C ile 15°C arasında ise sistemde hatalı çalışan enstrüman(lar) olduğunu ve bu durumun prosedürlere uygun şekilde giderilmesi gerektiğini ifade eder.
- Sıcaklık farkı 16°C ' den büyükse hatalı çalışan enstrüman(lar) olduğunu ve bu durumun hemen düzeltilmesi gerektiğini ifade eder.

Sıcaklık farkında ortam sıcaklığı göz önüne alınması gerekir ve ölçümler bu alanda yetkin bir personel tarafından yapılmalıdır.

Literatür incelendiğinde kızılötesi denetimle ilgili, özellikle bina ısı kaçakları, mekanik ekipmanların korozyon analizi ve elektrik izolasyon hata tespitlerinin yapıldığı görülmüştür (Bagavathiappan, S., ve ark. 2013; Jadin, M. S., ve ark., 2012; Singh, G., ve ark. 2016). Fakat bu tip denetimler sahada gerçekleştirilirken nitelikli ve deneyimli personeller tarafından yapılmadığı takdirde elde edilen sonuçların yanlış yorumlanabileceği ifade edilmiştir (Taib, S., ve ark., 2011).

Yangın güvenliği açısından can kayıpların yaşanmaması, yangın riskinin en düşük seviyede tutulması için diğer bir husus ise yanma başlamadan önce veya ilk yanma esnasında algılamanın hızlı yapılmasıdır. Günümüzde klasik yaklaşım örneklerine ait yangın algılama sistemleri, tavana monte edilen kablolu algılayıcılar ile yapılmaktadır. Özellikle BYKHY göre algılama sistemlerinin zorunlu olarak kullanılmasını gerektiren işyerlerinde tavana montajı yapılan algılayıcılar, meydana gelen yangını geç fark etmektedir. Bu durumda, işletme üretim kaybı, makine arızası, çalışanların yaralanması ve hatta can kaybı ile sonuçlanan kazalar yaşayabilir. Gelişen teknoloji sayesinde algılama sistemlerinin boyutları çok küçük ebatlara sığdırılabilmekte, tavan harici çeşitli noktalara montajı yapılabilmekte ve hatta kablosuz bağlantı ile uyarı verebilmektedir. Yangın algılama sistemleri, gaz, duman, ısı veya alev algılamaya dayalıdır. Ancak bu sistemler, yalnızca yeterli ısı üretildiğinde (ısı dedektörü), alev oluştuğunda (alev dedektörü) veya yeterli duman meydana geldiğinde uyarı verirler. Bu durum, bir dezavantaj olarak görülmektedir (Krüger, S., ve ark., 2017).

Son yıllarda, bilim insanları farklı çalışmalar ile yangın henüz başlamamışken koşulları izleyen hızlı ve güvenilir teknolojileri araştırmaktadır (Gaur, A., ve ark.,

2019, Solórzano A., ve ark., 2022, Sharma, A., ve ark., 2020). Bu teknolojiler arasında yapay zekâ ile geliştirilen birçok çalışma yapılmıştır. Yapay zekâ çeşitli başlıkları kapsayan bir konu olup, bu başlıklar arasında ML, doğal dil işleme, derin öğrenme gibi konular yer almaktadır. Yapay zekâ konularından biri olan derin öğrenme metodu ile yapılan çalışmalar incelendiğinde, bir çalışmada, orman yangınlarını tahmin etme üzerine derin öğrenme metodu ile donatılmış insansız hava aracı kullanılarak tahminleme yapılmıştır. Yapılan deneysel test uçuşlarında elde edilen sonuçların yaklaşık %90 seviyesinde doğru tahmin gerçekleştirdiği görülmüştür (Rathod, T., ve ark., 2023) . Başka bir çalışmada ise duman algılama sensörü, sıcaklık ve nem algılama sensörü ile bilgilerin orman sahasından toplanıp derin öğrenme ile işlendiği ve yapılan deney sayısının artması koşuluna bağlı olarak doğruluk seviyesinin %95 üzerine çıktığı ve çıkan sonuçların ilgili kişiyi uyardığı görülmüştür (Ananthi, J., ve ark., 2022). Farklı bir çalışmada, bina yangınlarını tahmin etmede, derin öğrenme metodu ile yapılan toplam 1845 simülasyon verisinin kullanıldığı, klasik duman karakteri sergileyen görüntülere dayalı derin öğrenme ile %96 oranında, farklı karakterdeki duman görüntülerine dayalı derin öğrenme ile %89 oranında başarılı bina yangınlarını tahmin edildiği görülmüştür (Wang, Z., ve ark., 2022). Robotik sistemler ile yangın yerini bulmaya yönelik diğer bir çalışmada ise yapay zekâ kullanarak yangınla mücadele robotlarının etkili şekilde yangın yönünü belirlemesi üzerinde deneyler yapılmıştır. Bu çalışmada, kapalı ortamda, yapay zekâ tekniklerini kullanarak ilerleyen bir yangın söndürme robotunun, eşik sınır değeri hesaplamalı sensörle çalışan yangın söndürme robotuna göre daha etkili sonuç verdiği görülmüştür (Ramasubramanian, S., ve ark., 2020). Diğer bir çalışmada ise yangın öncesi planlama ve operasyonel yangın yönetimi için potansiyel yangın kontrol konumlarını tahmin etmede ML metotlarından biri olan güçlendirilmiş lojistik regresyon modeli kullanılarak verilerin %69 doğrulukla tahmin gerçekleştirdiği görülmüştür (O'Connor, C. D., ve ark., 2017).

Bu çalışmada, IoT destekli, ML metoduyla elektrik pano yangınlarını erken algılamada bir çözüm aranmıştır. Deneysel çalışma yapılarak koşullar incelenmiştir. Deney amaçlı bir elektrik panosu kullanılmıştır. Pano içerisindeki kondansatöre enerji aktaran kablo farklılaştırılmıştır. Kesikli, ezik, zayıflatılmış kablo çeşitleri kullanılmış ve toplam 24 farklı deney gerçekleştirilmiştir. Bu deneylerde sekiz yanma ve yangın koşulları oluşmuştur. Veriler ve görüntüler IoT destekli sistemle toplanmıştır. Veriler Matlab aracılığı ile thingspeak.com bulut sisteme toplanmış ve ana bilgisayara

aktarılmıştır. Ana bilgisayarda çalıştırılan Matlab arayüzü ile veriler değerlendirilmiştir. Görüntüler Python ile Google Drive bulut sistemine aktarılmıştır. Bulut sistemden ana bilgisayara istenilen görüntü çağırılmaktadır. Tüm veriler sınıflandırılmış, ML metodunda değerlendirilmiştir. Elde edilen sonuçlar aşağıda bölüm dörtte değerlendirilmiştir. Klasik yangın algılama sistemlerine göre çalışmada kullanılan bu yöntem sayesinde normal çalışan sistem ve bir yangın başlangıç koşulları değerlendirilmiştir. Bulgulara göre uygulanan beş farklı İnce KA, İLR, GNB, Gaussian SVM ve KNN metotlarıdır. Sonuçları ise sırasıyla hem validasyon hem de test aşamalarında %98.7, validasyon sürecinde %95.0 doğruluk, test sürecinde %95.3, validasyonda %90.4 doğruluk test sürecinde bu oranı %91.2, hem validasyon hem de test süreçlerinde %99.3 ve son olarak validasyon sürecinde %98.7 test sürecinde bu oranı %99.3 şeklindedir.

1.1. Tezin Kapsamı

Bu tezin kapsamı, elektrik panolarında yangın risklerini azaltmayı ve yangın güvenliği önlemlerinin etkinliğini artırmayı hedeflemektedir. Bu hedef doğrultusunda, nesnelerin interneti ve makine öğrenmesi tabanlı sistemlerin gerçek zamanlı veri toplama, işleme ve analiz kabiliyetlerinin, yangın güvenliği uygulaması olarak dönüşümü üzerinde çalışılmıştır. Veriler anlık olarak Arduino Mega ve Raspberry Pi 4 platformları üzerinden toplanmış, bulut sistemine kopyalanmış ve bulut sisteminden de ana makine için Matlab (akademik versiyon) programı ile geliştirilen izleme ve raporlama uygulamasına aktarılması sağlanmıştır. Son olarak, veriler Matlab programı aracılığıyla beş farklı denetimli makine öğrenimi metodunu kullanarak işlenmiş ve bu işlemlerin sonuçları analiz edilmiştir.

1.2. Tezin amacı

Bu tezin amacı, elektrik panolarında yangın riskini minimize etmek ve yangın güvenliği önlemlerinin etkinliğini artırmak için nesnelerin interneti ve makine öğrenmesi teknolojilerini bir panoya entegre edilmesini sağlayarak, yenilikçi bir algılama ve önleme sistemi geliştirmektir. Çalışma, erken yangın tespiti ve potansiyel arızaların proaktif yönetimi konularında, kestirimci bakım anlayışı ile gelişmiş teknolojik yaklaşımların uygulanabilirliğini ve etkinliğini değerlendirmeyi amaçlar.

Bu sayede, elektrik panolarının güvenliğini artırarak olası can ve mal kayıplarının önüne geçilmesine imkan sağlanacaktır.

1.2.1. Tezin ikincil amacı

Bu tezin ikincil amacı, toplanan verilerin makine öğrenmesi tabanlı yangın algılama ve önleme sisteminin performansını değerlendirerek, bir model oluşturmaktır. Çalışma, bu teknolojilerin pratikteki uygulanabilirliğini ve yangın güvenliği yönetimini nasıl iyileştirebileceğini göstermeyi amaçlamaktadır. Toplanan verilerin analizi ile yangın risk değerlendirmelerinin daha doğru ve zamanında yapılmasını sağlamak da diğer bir hedeftir.

1.3. Hipotez

Bu çalışması için hipotez önerisi, şu şekilde ifade edilmektedir;

Nesnelerin İnterneti ve makine öğrenmesi algoritmaları kullanan teknoloji entegrasyonunun, elektrik panolarında erken yangın algılama ve önleme kabiliyetini önemli ölçüde artıracığı ve bu entegrasyonun, geleneksel yangın algılama sistemlerine kıyasla daha etkili olacağı varsayılmaktadır. Bu hipotez, çalışmanın potansiyel etkinliklerini somut bir şekilde test etmek üzerine kurulmuştur. Hipotezin doğrulanması durumunda, elektrik panoları için geliştirilen bu yenilikçi yaklaşımın bilimsel bir temel oluşturacağı düşünülmektedir.



2. LİTERATÜR TARAMASI

2.1. Yanma Nedir

Yangın bilimi, yangın güvenliği ve yangın algılama stratejileri akademik çalışmaların da konusu olmuştur (Chuvieco, E., ve ark. 2020; Geetha, S., ve ark. 2021; Liu, J., ve ark. 2020; Morélot, S., ve ark. 2021). Yangın riskini değerlendirme, yangınların erken tespit edilmesi ve yangın güvenliği önlemlerinin geliştirilmesi çeşitli akademik araştırmalar ve uygulamalarda değerlendirilmiştir. Bir yangın, yanma süreci ile başlar. Yanma, bir çeşit kimyasal reaksiyon sürecidir. Bu süreç enerji, ısı veya iş amaçlı kullanılmakta olup, genelde yakıt olabilecek bir maddenin yeterli ısı ve oksijen ile tepkimeye girmesiyle başlar(Kohse-Höinghaus, K. 2023). Yanma gerçekleşirken yakıt olarak kullanılan maddenin molekülleri ile oksijen molekülleri tepkimeye girer reaksiyon sonucunda enerji ve diğer yanma ürünleri elde edilir. Yanma reaksiyonu için genel olarak kullanılabilen basit denklem aşağıda verilmiştir.

Yakıt + Oksijen(Yakıcı madde) → Isı + Işık + Yanma Ürünleri (Murty, K. A., 1975 ; Sullivan, A. L., 2017)

Yanma şartları dikkatsizce veya kontrolsüzce gerçekleştirilirse yangına sebep olan tehlikeli durumları meydana getirebilir. Yangın, yanma olayının hızla ve kontrolsüz biçimde yayılarak enerjinin kontrol edilememesi durumudur (Lieberman, M. A., 2010).

Yanma koşullarının gerçekleşmesindeki gibi yangında da üç temel bileşenin birleşmesiyle gerçekleşir. Bunlar yakıt, ısı ve yakıcı madde yani oksijendir (Bickerton, J., 2012; Gamble, C. E., ve ark. 2010).


Yanıcı madde olarak adlandırılan, yangının beslendiği maddeye yakıt denir. Katı, sıvı ve gaz gibi çeşitli fazlarda bulunabilir. Katı için odun ve kâğıt, sıvı için benzin ve mazot, gaz için propan ve doğalgaz örneği verilebilir.

Yanmanın gerçekleşebilmesi için gereken diğer bir madde ise yakıcı maddedir. Normal şartlar altında hava içindeki yakıcı madde olarak bilinen oksijen yüksekliğe bağlı olarak % 19.5-23.5 oranı aralığında bulunur (Occupational Safety and Health

Administration (29). CFR 1910.134; Cohen, Howard J. Ve ark. 2012). Oksijenin varlığı olmadan yanma gerçekleşmeyecektir.

Doğada, özellikle ormanlık alanlarda yakıt olarak kullanılabilen, katı madde formunda yer alan ağaçlar bulunmaktadır. Ayrıca hava içerisinde yakıcı madde olarak kullanılan oksijen de bulunmaktadır. Yanıcı madde ve yakıcı madde bulunuyorken, yeterli enerji (ısı) bulunmadığı sürece yanma meydana gelmeyecektir. Yanma reaksiyonunu başlatmak ve sürdürmek için gerekli olan ısı, yanma reaksiyonunu başlatmak ve sürdürmek için gereklidir. İlk aşamada dış ortamdan gelen bir ısı kaynağı yangını başlatabilir. Sonraki süreçte yangın büyüdükçe ısı yayılarak etrafındaki diğer yanıcı maddelere sirayet edecektir. Bu yangının büyümesine ve kontrol edilmesinin güçleşmesine sebep verecektir.

Yangın için gerekli olan üç temel unsurun gösterimi aşağıdaki gibidir.




Şekil 2.1. (a)Yangın üçgeni, (b)parlama dörtgeni, (c)patlama beşgeni (OSHA 3644-04, 2013).

Yukarıda gösterilen Şekil 2.1. (a)'da yeterli miktarda oksijen, yanıcı madde ve yeterli sıcaklık (ısı) birleşmesi yangını meydana getirdiği görsel olarak ifade edilmektedir. Bu durum yangın üçgeni olarak adlandırılmaktadır. Şekil 2.1. (b)'de ise uygun miktarda yanıcı toz, dağılıp bulut halinde yeterli ısı kaynağı ile buluştuğunda ani bir parlamaya neden olur. Bu ani parlama, sıradan bir yangından çok daha tehlikelidir. Parlama sırasında insanlar kaçamayarak alev topu içerisinde kalabilir. Bu alev topu bir anda meydana gelir ve kaybolur. Yangın üçgeninden farklı olarak parlamanın meydana gelmesi için yanıcı bir toz bulutunun ortaya çıkması ve yayılma etkisini göstermesi gereklidir. Şekil 2.1. (c)'de patlama beşgeni görsel olarak ifade edilmiştir. Ani bir yangının sınırlandırılması esnasında gerçekleşen, gelişen basınç bir patlamaya neden olabilir ve kapalı muhafazanın tahrip olmasına yol açabilir. Bu sınırlandırılmış alan, bir ekipman, bir toz toplayıcı kabin, bir oda veya binanın tamamı olabilir. Dolayısıyla patlama sonucu oluşan ve şarapnel etkisi oluşturan cisim parçacıkları, patlama basınç dalgası ve çöken yapı, alan içindeki ve etrafındaki insanları yaralayabilir veya can

kayıplarına sebep verebilir. Yanıcı toz, kapalı alan, tutuşma kaynağı, oksijen ve yayılma etkisi koşulları (Bakdemir, S. A., ve ark. 2021) patlama beşgenini ifade eder. Bir patlamada meydana gelen basınç dalgası, çalışma veya depolama alanlarındaki biriktirilen yanıcı tozu dağıtarak artarda patlamalara neden olabilir. İkincil patlamalar olarak adlandırılan bu patlamalar, ilk patlamadan daha yıkıcıdır ve tesisin her yerine yayılması muhtemeldir.

Bir yanma olayının, kontrol dışına çıkıp herhangi bir yangına sebep vermemesi veya meydana gelse bile ivedi şekilde kontrol altına alınıp, söndürülmesi için çeşitli yöntemler ve ekipmanlar kullanılır. Bu yöntemler yangın güvenliği altında değerlendirilir. Yangın güvenliği, bu alanda kendini geliştirmiş ve yangın söndürme eğitimi almış profesyoneller tarafından uygulanır. Yangınlar ciddi zararlara yol açabileceğinden, yangın güvenliği önlemlerine uymak can ve mal kayıplarının önüne geçme açısından büyük önem taşır. Temelde, yangın güvenliği aktif ve pasif yangın güvenlik önlemleri olarak iki başlık altında değerlendirilir ve amaç insanların güvenliğini sağlanması, tesisin ve işletmenin hasarsız veya en az hasarla süreci atlatmasıdır. Bu amaç doğrultusunda yangınların kontrol altına alınması için kullanılan iki farklı yaklaşım bulunmaktadır. Bunlar pasif ve aktif yangın güvenliği sistemleridir (Boroń, S. ve ark. 2019; Wang, B., ve ark. 2017).



Şekil 2.2. Yeni nesil akıllı algılayıcılar (Lv, L. Y., ve ark. 2022)

Şekil 2.2.'de yangın güvenliği stratejisine yönelik yeni yaklaşım sunulmaktadır. Yangın güvenlik stratejileri genellikle aktif ve pasif olmak üzere iki temel güvenlik önlemi kategorisine ayrılmaktadır. Aktif yangın önlemleri, yangın algılama ve müdahale sistemlerini içerir; bu sistemler arasında duman ve ısı sensörleri ile devriye ekibinin varlığı bulunmaktadır. Bu önlemler, yangının erken evrelerde tespit edilmesini ve hızlı bir şekilde müdahale edilerek kontrol altına alınmasını amaçlamaktadır. Öte yandan, pasif yangın güvenlik önlemleri, yangının yayılmasını engellemek ve yapısal bütünlüğü korumak için tasarlanmıştır. Bu kapsamda, iç mekanlarda alevi modifiye edilmiş malzemelerin kullanımı ve yüzeylerde alev geciktirici kaplamaların uygulanması yer almaktadır. Pasif önlemler, aktif sistemlerin tamamlayıcısı olarak işlev görür ve yangının olumsuz etkilerini azaltmada hayati öneme sahiptir. Bu iki güvenlik stratejisi, yangına karşı kapsamlı bir koruma sağlamak için birlikte ele alınmalıdır. Yeni nesil akıllı algılayıcılar, aktif ve pasif yangın güvenlik önlemlerinin bütünleşmiş bir şekilde çalışmasını sağlayarak yangın güvenliği alanında bir dönüşüm yaratmaktadır. Bu akıllı sistemler, yangın algılama ve müdahale süreçlerini daha etkin hale getirirken, aynı zamanda bina içerisindeki yangın güvenlik malzemelerinin ve yapısal elemanların performansını izleyebilmektedir.

Pasif yangın güvenliği, yangın riskini en düşük seviyede tutma ve yangının yayılmasını sınırlamak amacıyla ele alınan bir takım yapısal önlemleri içerir (Mróz, K., ve ark. 2016). Bir yapının tasarım ve inşaa aşamasında alınan tedbirler sayesinde, yangının yayılmasını sınırlamayı, mümkün olduğunca hasarı en az seviyede tutmayı amaçlar. Aslında bu tür önlemler, yangın sırasında doğrudan devreye girmez, yapı bileşenlerinin tasarım ve malzeme seçimi ile ilgilidir. Pasif yangın güvenlik önlemlerine verilebilecek iyi örnekler arasında yangının yayılmasını engellemek için kullanılan yangın bölme duvarları ve zeminlerin uygun şekilde oluşturulması, yangının odalardan diğer bölgelere sıçramasını engellemek için kullanılan yangına dirençli kapıların kullanılması, yangının yayılmasını geciktiren ve yangına dayanıklılığı artıran yanmaz yalıtım malzemelerinin kullanılması, yangına karşı dayanıklılığı arttıran kaplama ve boyaların kullanılması ve insanların güvenli bir şekilde binadan tahliyesini sağlayan kaçış yollarının uygun şekilde düzenlenmesidir (Korkmaz, E., 2016).

Aktif yangın güvenliği ise yangın anında hızlı bir şekilde devreye giren ve yangına müdahaleyi sağlayan sistemlerin tümüdür. Meydana gelen bir yangının kontrol altına

alınması için kullanılan ekipman ve sistemler bu kapsamda değerlendirilir. Aktif yangın güvenlik sistemleri, yangın anında otomatik veya manuel çalıştırılır. Bu sistemlerde, yangın algılamada kullanılan duman, ısı, alev, gaz yoğunluğu detektörleri, algılama sensörleri tarafından toplanan verileri işlemede ve doğrulamada kullanılan kontrol panelleri, söndürme işlemlerinde kullanılan soğutma etkisi oluşturan su, boğma etkisi oluşturan köpük vb. unsurları kullanan söndürme maddelerini ve bunları püskürtmede kullanılan sistemleri barındırır (Demirel, F., ve ark. 2006; Bodur, A., 2020). Bunlardan hariç taşınabilir yangın söndürme cihazları (YSC), yeterli su sağlamak için kullanılan su deposu, yangın pompaları ve hidrantlar da aktif yangın güvenlik sistemleri içerisinde değerlendirilir. Aktif yangın güvenlik önlemlerinde kullanılan tüm sistemlerinin, her daim çalışır olması gerekir. Ayrıca tüm aktif ve pasif yangın güvenlik önlemlerinin ilgili yönetmelik ve standartlara göre tasarımlarının yapılmış olması ve düzenli bakımları tamamlanması gerekir (Binaların Yangından Korunması Hakkında Yönetmelik, 2007).

Aktif güvenlik sistemleri içinde erken tespit ve hızlı müdahalenin aktifleştirilmesinde kullanılan, algılama sistemlerinde kullanılan dedektör teknolojileri arasında duman, ısı, alev, gaz yoğunluk, lineer ile termal kamera ile algılama sistemleri yer alır (Memane, S. E., ve ark. 2015; Zhang, Y., ve ark. 2021; Barmpoutis, P., ve ark. 2020; Valikhujayev, Y, 2020). Yangın esnasında meydana gelen dumanı algılayarak alarm veren dedektör çeşidi duman dedektörleri olarak adlandırılır ve farklı tipleri bulunmaktadır (Khan, F., ve ark. 2022). Bunlar arasında optik, iyonizasyon gibi dedektörler yer alır. Optik duman dedektörleri, bir ışık kaynağı ve bir fotodedektör içerir (Wei, M. C., ve ark. 2021). Yangın esnasında duman ortaya çıktığında, dedektör tarafından algılanan ışık miktarında bir azalmaya meydana gelir (Zhdanova, A., 2022). Azalan ışık seviyesi dedektörü aktif eder ve kontrol panosundaki alarmı çalıştıracak sinyali üretir. İyonizasyon duman dedektörü çalışma prensibi olarak içinde bulunan iki elektrik yüklü plaka sayesinde iyonlaşma gerçekleştirilir (Solórzano A., ve ark. 2022). Yangın esnasında ortaya çıkan duman iyonlaşma esnasında elektrik akımını değiştirir (Cleary, T. 2014). Akımdaki değişiklik kontrol panosundaki alarmı çalıştıracak sinyali üretir.

2.2. Dedektörler

2.2.1. Isı dedektörleri

Ortamda anormal ısı artışını algılar (Khan, F.,ve ark. 2022). Sabit sıcaklık, değişken sıcaklık ve hızlı artış gibi çeşitli tipleri vardır. Sabit sıcaklık ısı dedektörü belirli bir sıcaklık eşiğine ayarlanmıştır. Koşullar sürekli olarak izlenir. Belirlenen eşik aşılsa dedektör alarm sinyali üretir. Değişken sıcaklık ısı dedektörleri, ortam sıcaklığını izler ve anormal artış tespit edildiğinde dedektör alarm sinyali üretir. Hızlı artış ısı dedektörleri ise ortamdaki sıcaklık değişim hızını ölçmektedir ve belli bir zaman diliminde belirgin bir sıcaklık artışı algılandığında, dedektör alarm sinyali üretir. Aşağıdaki Şekil 2.3.'te bir ısı dedektörünün görseli verilmiştir.



Şekil 2.3. Isı dedektörü

Şekil 2.3., yangın algılama sistemlerinde kullanılan, önceden ayarlanabilen ve belirli bir sıcaklık seviyesine ulaşıldığında veya sıcaklık belirli bir hızda arttığında aktif hale gelen ısı dedektörünün görselidir.

2.2.2. Alev dedektörleri

Yanma esnasında ortamdaki alevi algılamak için kullanılan, görsel veya özel dalga boylarını izleyen bir yapıya sahiptir. Ortamdaki kızılötesi (IR) veya ultraviyole (UV) ışınları algılar (Kushnir, A., ve ark. 2021). IR tipi alev dedektörleri, yanma esnasında oluşan belirli dalga boylarındaki kızılötesi ışınları algılar ve dedektör alarm sinyali üretir. UV tipi alev dedektörleri ise yanma esnasında üretilen ultraviyole ışınları algılar ve dedektör alarm sinyali üretir. Bunlardan hariç çok spektrumlu alev dedektörleri de bulunur. Bu tip dedektörler hem kızılötesi hem de ultraviyole dalga boyundaki ışınları algılayabilen yapıdadır (Pittman, W., ve ark., 2023). Aşağıdaki Şekil 2.4.'te bir alev dedektörünün görseli verilmiştir.



Şekil 2.4. Alev dedektörü

Şekil 2.4.'te genellikle büyük depolarda, endüstriyel tesislerde veya herhangi bir yangın riskinin yüksek olduğu ortamlarda kullanılan alev dedektörüdür. Diğer dedektörlere göre maliyeti fazla olup, daha çok geniş alanlarda tercih edilirler.

2.2.3. Gaz dedektörleri

Algılanması istenen gazların varlığına göre çalışan yapıdadır Özellikle endüstriyel tesislerde kullanılır. Karbon monoksit (CO), metan (CH₄) vb. gaz dedektörlerinin yanı sıra karışık gaz algılayan çeşitleri de bulunur (Li, Y., ve ark. 2022; Raza, M., ve ark. 2023; Tian, F. C., ve ark. 2022). CO dedektörleri, kimyasal boğucu etkiye sahip ve kapalı ortamlarda canlılar için tehlike oluşturan bu gaz için tasarlanmıştır. Gaz sızıntılarını algılayarak veya birikimleri tespit ederek çalışan gaz dedektörü ise CH₄ dedektörüdür. Bu dedektör tipi doğal gaz sızıntılarını algılamada da kullanılmaktadır. Doğal gazın ana bileşeni CH₄ gazıdır. Birçok farklı gazın varlığını algılamak üzere tasarlanmış dedektörler çoklu gaz dedektörleridir. Genellikle CH₄, propan (C₃H₈), CO, hidrojen (H₂), karbon dioksit (CO₂) gibi gazları tespit etmek için kullanılır. Aşağıdaki Şekil 2.5.'te bir gaz dedektörünün görseli verilmiştir.




Şekil 2.5. Gaz dedektörü

Şekil 2.5. gaz sızıntılarını erken aşamada tespit ederek olası yangın, patlama veya zehirlenme risklerini önlemeye yardımcı olan dedektördür. Hava kalitesi kontrolü ve maliyet etkinliği açısından avantajları vardır. Fakat çabuk arızalanabilirler.

2.2.4. Lineer dedektör

Uzun hat boyunca kablo veya boru şeklinde tasarlanmış algılayıcı sistemlerdir (Junwei, D. ve ark. 2020). Hat boyunca değişiklikleri izler ve algılama yaptığında sinyal üreterek kontrol panosuna iletir. Bu dedektör tipi lineer ısı algılama kabloları veya lineer optik duman algılama kabloları şeklinde çeşitlenir. Lineer ısı algılama, kablo içine yerleştirilmiş ısı algılayıcıları kullanır. Kablo belirli bir sıcaklık üzerindeki değişiklikleri algılar ve kontrol panosuna sinyal gönderir. Lineer optik duman algılama ise kablodan geçen dumanı veya partikül yoğunluğu değişikliğini algılayan bir yapıya sahiptir. Aşağıdaki Şekil 2.6.'da bir lineer dedektörün yapısına ait görseli verilmiştir.




Şekil 2.6. Lineer dedektör yapısı

Şekil 2.6. daha çok büyük depolar, tüneller, geniş kapalı otoparklar ve çeşitli üretim tesislerinde tercih edilen, fakat işçiliği maliyetli olan bir lineer dedektör yapısını göstermektedir.

2.2.5. Termal kameralar

Bu kameralar ile algılama sistemi, görüntüleme teknolojisi kullanarak nesnelerin veya ortamın sıcaklık farklılıklarını tespit eder ve yangın belirtilerini görsel olarak ilgili ekrana paylaşır (Quttineh, N. H., ve ark. 2022; Sadi, M., ve ark. 2021). Yüksek çözünürlüklü, sabit tip ve yatay, dikey, yakınlaştırmalı termal kamera çeşitleri yangın algılama için kullanılmaktadır. Aşağıdaki Şekil 2.7.'de bir termal kamera, görüntülediği ortam ve termal görüntüsüne ait görsel paylaşılmıştır.



Şekil 2.7. (a)Termal kamera (b) görüntülenen ortam (c) termal görüntü

Şekil 2.7, termal görüntüleme teknolojisinin bir uygulamasını üç bölümde sunmaktadır: (a) Termal kamera, bu teknolojinin temel aracını temsil eder ve çevresel ısı varyasyonlarını algılayabilen bir sensöre sahiptir. (b) Görüntülenen ortam, termal kameranın odaklandığı fiziksel mekânı gösterir, burada farklı nesneler ve yapılar bulunmaktadır. (c) Termal görüntü, görüntülenen ortamdaki ısı dağılımını renk kodları aracılığıyla görselleştirir, böylece sıcaklık farklılıkları net bir şekilde ayırt edilebilir. Bu şekil, termal kamera teknolojisinin, ısı ile ilgili bilgileri görsel bir formatta sunarak, sıcaklıkla ilişkili analizlerin yapılmasına olanak tanımaktadır

Dedektörlerin genel değerlendirilmesi amaçlı aşağıda Tablo 2.1. hazırlanmıştır.

Tablo 2.1. Yangın algılayıcı tipleri, özellikler ve kullanım alanları

Tip	Avantajlar	Kısıtlar	Kullanım Alanı
Duman dedektörü	Hızlı tepki ve erken uyarı, kolay kurulum, uzun ömür, düşük maliyet.	Tep tip algılama.	Genellikle konutlarda tercih edilir.
Isı dedektörü	Düşük yanlış alarm riski, dumansız veya az duman içeren yangınları algılama.	Belirli sıcaklık aralığında çalışabilme, belirli uygulama alanlarında kullanım.	Endüstriyel tesisler (Enerji santralleri, Depolama ve lojistik tesisleri vb.) Taşıma araçları (gemi, tren, uçak).
Alev dedektörü	Erken algılama, düşük yanlış alarm oranını, çeşitli alev tiplerini algılama.	Belirli alev tipleri için özelleştirme ihtiyacı, belirli alanlarda kullanım.	Petrol ve gaz endüstrisi, depolama tesisleri.
Gaz dedektörü	Çeşitli gazları algılama, güvenilir, hızlı tepki ve erken uyarı, hassaslık.	Çok düşük veya çok yüksek miktardaki gazları algılayamama.	Kimya, rafineri, gıda ve işlenmiş ürün tesisleri ile yer altı madencilik
Lineer dedektör	Uzun mesafe kapsama, düşük enerji tüketimi, hızlı tepki süresi, kolay kurulum.	Sınırlı algılama alanı	Ulaşım (karayolu tünelleri, metro hatları, yer altı kapalı otoparkları vb.)
Termal Kamera	Görünmeyen (H ₂) yangınları algılama, geniş alan kapsama, uzaktan izleme, uzun menzil, erken teşhis	Sıcak yüzeylerle çalışan alanlarda kullanılamama	Ormanlık ve tarım alanları, enerji iletim hatları, petrol ve gaz tesisleri

Tablo 2.1., çeşitli yangın algılayıcı tiplerini, bu algılayıcıların avantajlarını, kısıtlarını ve potansiyel kullanım alanlarını özetlemektedir. Duman dedektörleri, hızlı tepki süreleri ve erken uyarı özellikleri ile öne çıkar; genellikle konutlarda tercih edilirken, tek tip algılama kapasiteleri sınırlılıklarını oluşturmaktadır. Isı dedektörleri, özellikle dumansız veya az duman üreten yangınlarda düşük yanlış alarm riski sunarak,

endüstriyel tesisler ve taşıma araçlarında (gemi, tren, uçak) kullanıma uygun olduğunu kanıtlamaktadır. Alev dedektörleri, erken algılama kapasitesi ve düşük yanlış alarm oranı ile petrol ve gaz endüstrisi gibi özel sektörlerde tercih edilmekte, ancak belirli alev tiplerine özelleştirilmiş algılama gerektirebilmektedir. Gaz dedektörleri, hassas ve güvenilir algılama yetenekleri sayesinde, kimya, rafineri, gıda işleme ve yer altı madenciliği gibi çeşitli sektörlerde geniş bir kullanım alanı bulmaktadır. Lineer dedektörler, uzun mesafeleri kapsayabilme yetenekleri ile ulaşım sektöründe, özellikle karayolu tünelleri ve metro hatları gibi alanlarda önemli bir rol oynamaktadır. Termal kameralar ise, H₂ yangınları gibi görünmeyen yangınları algılama kapasiteleri ile ormanlık alanlar, enerji iletim hatları ve petrol ile gaz tesisleri gibi geniş alanların izlenmesinde kritik öneme sahiptir. Bu çeşitlilik, yangın algılama ve önleme sistemlerinin, farklı riskler ve ihtiyaçlar doğrultusunda özel olarak değerlendirilir ve kurulumları gerçekleştirilir.

Yangın algılamada kullanılan sistemler, birden çok dedektör ve sensörün beraber kullanıldığı kompleks sistemlerdir. Bu sistemlerin kompleksliği, yanlış alarm riskini azaltma ve farklı yangın türlerini belirlemede kullanılır. Bu sayede algılama sisteminin tepki süresi düşer, doğru bilgi aktarır ve güvenilirlik seviyesi artar.

2.3. Elektrik panosu ve türleri

Günümüzde, akıllı trafo merkezleri gelişmiş ülkelerde bulunmaktadır. Bu merkezlerde iletişim özellikli orta gerilim şalt cihazları, orta ve alçak gerilim şebekesini izleyen ve kontrol eden bütünleşmiş uzaktan kumanda ve otomasyon çözümleri bulunmaktadır (Dileep, G. J. R. E., 2020).

Elektrik panosu, elektrik tesisatında güç dağıtımını kontrol eden, koruyan ve düzenleyen bileşenlerdir (Sărăcin, C. G., ve ark. 2021). Kullanım amacına göre birçok çeşidi vardır. Dağıtım panosu, tesisattaki elektrik enerjisini kontrol eden ve yönlendiren türdeki panodur. Ana dağıtım panosu (Gammon, T., ve ark. 2001) gelen enerjinin tesisata giriş yaptığı, genel enerji dağıtım noktalarını kontrol eden panodur. Genelde elektrik şebekesinden gelen yüksek gerilimli elektriği daha düşük gerilim seviyelerine düşürür. Alt dağıtım panosu (Gammon, T., ve ark. 2001) ise ana dağıtım panosundan gelen enerjiyi belirli alanlara yönlendirir ve binada farklı alanlara enerji sağlamak üzere konumlandırılır. Motor kontrol panosu, tesislerde kullanılan elektrik motorlarını kontrol etmek, korumak ve yönlendirmek için tasarlanmışlardır. Güçlü

elektrik motorların başlatma esnasında fazla akım çekmelerini önlemek ve arızalanmasını engellemek için yıldız-üçgen (delta) yol verme, motor kontrol panosunda kullanılır (Itajiba, J. A., ve ark 2021). Başlatma yıldız bağlantı üzerinden üçgen bağlantıya geçilerek yapılır. Programlanabilir kontrol sistemli (PLC) motor kontrol panosu otomatik kontrol sistemi içerir. Endüstriyel tesislerde çokça kullanılır. Aydınlatma panosu aydınlatma sistemini kontrol etmek, yönlendirmek ve korumak için kullanılır. Ana aydınlatma , kat aydınlatma, dış aydınlatma gibi türleri bulunur. Güç faktörü düzeltme panosu (Baek, J., ve ark. 2021) ise elektrik sistemindeki güç faktörünü optimize etmek için kullanılır. Elektrik sistemindeki aktif gücün, reaktif güce oranı güç faktörü olarak tanımlanır. Düşük güç faktörü, enerji verimliliğini azaltır ve enerji maliyetini yükseltir. İşte bu noktada güç faktörü düzeltme panosu, sistemin güç faktörünü iyileştirmek için kullanılır. Kapasitif, endüktif, kontaktör kontrollü gibi türleri bulunur. Elektrik tesisatında ana güç kaynağındaki bir arıza durumunda veya voltaj düşüşü gibi belirli koşullar karşılandığında otomatik olarak yedek güç kaynağına geçiş otomatik transfer anahtarı panosu ile yapılır. Çift geçişli, güç faktörü düzeltmeli, tek fazlı, üç fazlı gibi çeşitleri bulunur. Telekomünikasyon panosu (Bogetić, Ž., ve ark. 2006), telekomünikasyon ekipmanlarının güç kaynağını sağlayan, kontrol etmek amacıyla kullanılan, iletişim altyapısını güvenli şekilde çalıştıran pano türüdür. Genelde telekomünikasyon ekipmanları doğru akım (DC) ile çalışır. Dolayısıyla telekomünikasyon pano türleri arasında DC güç dağıtım, AC-DC konvertör, yedek güç kaynaklı ve veri iletişim panosu gibi çeşitleri bulunur. Yukarıdaki pano çeşitlerinden hariç ayrıca kumanda panolarından da bahsedilebilir. Bu pano çeşidi, endüstriyel otomasyon sistemlerinde kullanılan bir kontrol panelidir. Bu panolar, makineleri, motorları veya diğer elektrikli cihazları kontrol etmek ve izlemek amacıyla kullanılır.

2.4. Elektrik panolarında kullanılan elemanlar

Elektrik panolarında birçok eleman kullanılır. Bu elemanların çeşitliliği panonun görevine göre değişkenlik gösterir. Elektrik enerjisini dağıtmak, kontrol etmek ve düzenlemek için kullanılan bu elemanların bazıları aşağıda Tablo 2.2’de verilmiştir.

Tablo 2.2. Pano içi elektriksel elemanları

Ürün	Görsel	Açıklama
Ana Kesici (Cooley, J. J., ve ark. 2010)		Tüm panoyu kapatıp açan, ana hattı kontrol eden bir anahtardır.
Devre Kesici (Cooley, J. J., ve ark. 2010)		Elektrik panosundaki devreleri korumak için kullanılan, aşırı akım, kısa devre veya diğer tehlikeli durumlar algılandığında devreyi otomatik olarak kesen elemanlardır
Sigorta (Velásquez, R. A. 2022).		Aşırı akım durumlarında eriyerek devreyi kesen devre kesicilerin aksine genellikle otomatik bir sıfırlama özelliği olmayan elemanlardır.
Koruma Rölesi (Kiliçkiran, H. C., ve ark. 2018)		Bu eleman devreleri aşırı akım, kısa devre, düşük gerilim, yük dengesizlikleri gibi potansiyel tehlikeli durumlar ve arızalar karşısında korumak için kullanılır.
Transformatör (Awadallah, M. A., ve ark. 2015)		Düşük voltajı yüksek voltaja veya tersine çevirmek için kullanılan elemandır.
Klemens (Yeon, Y. M., ve ark. 2020)		Panodaki kabloları düzenlemek, izole etmek ve korumak için kullanılan bağlantı kutularıdır.
Kondansatör (Hoq, M. T., ve ark. 2021)		Güç faktörünü düzeltmek ve enerji verimliliğini artırmak amacıyla kullanılan elemanlardır.
Sayaç (O'driscoll, E., ve ark. 2013)		Tüketilen elektrik miktarını ölçen, faturalandırma işlemlerinde kullanılan elemandır.
İletkenler (Kablolar) (Song, H. C., ve ark. 2017)		Elektrik enerjisinin bir noktadan diğerine güvenli ve etkili bir şekilde taşınmada kullanılan kablolar teller, yalıtkanlar ve koruyucu kaplamadan oluşur.
Kablo Pabuçları (Seefried, J., ve ark. 2017)		Elektrik kablo uçlarını bir araya getirerek kablolarının birbirine veya diğer elektriksel cihazlara güvenli şekilde bağlanmasını sağlar.

Tablo 2.2., elektrik panolarında kullanılan çeşitli elektriksel elemanların bir özetini sunmakta ve bu elemanların her birinin temel işlevini açıklamaktadır. Ana kesici, panonun tamamını kontrol eden anahtar görevi görerek, tüm sistemi kapatıp açabilme özelliğine sahiptir (Cooley, J. J., ve ark., 2010). Devre kesiciler, aşırı akım, kısa devre gibi tehlikeli durumları algıladığında devreyi otomatik olarak keserek elektrik panolarındaki devreleri korumak için tasarlanmıştır (Cooley, J. J., ve ark., 2010). Sigortalar ise, aşırı akım durumlarında devreyi kesen, ancak genellikle otomatik olarak sıfırlanmayan koruyucu elemanlardır (Velásquez, R. A., 2022). Koruma röleleri, devreleri aşırı akım, kısa devre, düşük gerilim gibi tehlikeli durumlardan korumak için kullanılır (Kiliçkiran, H. C., ve ark., 2018). Transformatörler, voltajı yükseltmek veya düşürmek için kullanılan elemanlardır (Awadallah, M. A., ve ark., 2015). Klemensler, panodaki kabloları düzenleyen, izole eden ve koruyan bağlantı kutularıdır (Yeon, Y. M., ve ark., 2020). Kondansatörler, güç faktörünü düzeltmek ve enerji verimliliğini artırmak amacıyla kullanılır (Hoq, M. T., ve ark., 2021). Sayaçlar, tüketilen elektrik miktarını ölçerek faturalandırma işlemlerinde kullanılır (O'driscoll, E., ve ark., 2013). İletkenler (kablolar), elektrik enerjisini bir noktadan diğerine taşımak için kullanılan kritik bileşenlerdir ve teller, yalıtkanlar, koruyucu kaplamalar içerir (Song, H. C., ve ark., 2017). Son olarak, kablo pabuçları, kablo uçlarının güvenli bir şekilde birbirine veya diğer elektriksel cihazlara bağlanmasını sağlar (Seefried, J., ve ark., 2017). Bu elemanlar, elektrik enerjisinin dağıtımı, kontrolü ve düzenlenmesi işlevlerinde merkezi roller üstlenirler ve panonun görevine göre çeşitlilik gösterirler.

2.5. Elektrik Kablolarında Kullanılan İzolasyon Çeşitleri

Elektrik kabloları kullanım amacına, enerji iletim gereksinimine ve kullanım alanına göre çeşitlilik gösterir. Tek telli, çok telli, örgü ekranlı vb. çeşitleri elektrik iletimini sağlarken, dış ortamı iletilen enerjiden korumak için tel etrafına sarılan bir izolasyon malzemesi ile kaplanır. Bu izolasyon malzemesini birçok tipte olabilir. En yaygın kullanılan tipler ise Polivinil Klorür (PVC) (Abdel-Gawad, N. M., ve ark. 2018), çapraz bağlı polietilen (Ul-Hamid, A., ve ark. 2015) (XLPE), etilen propilen kauçuğu (Verardi, L., ve ark. 2014) (EPR), silikon kauçuk ve termoplastik plastomerdir (Ismail, N. H., ve ark. 2018) (TPE).

PVC, genellikle bakır iletkenleri birbirinden ve dış etkenlerden izole eden malzemedir ve maliyet açısından ekonomiktir (Mandadi, G. K., ve ark. 2020). Düşük gerilimli

enerji dağıtım sistemlerinde yaygın olarak kullanılır. Endüstriyel tesislerde, ticari binalarda ve konutlarda çeşitli elektriksel uygulamalarda kullanılabilir.


XLPE, yüksek gerilim uygulamalarında bakır veya alüminyum iletkenleri izole etmede kullanılır (Thomas, J., ve ark. 2019). Yüksek sıcaklık koşullarına, mekanik streslere karşı dayanıklıdır. Genelde madenlerde ve enerji üretim tesislerinde kullanılan bu izolasyon tipine sahip kablolar uzun ömürlü ve dayanıklı bir performans sağlar.

EPR, orta gerilim uygulamalarında kullanılan, yüksek sıcaklık ve mekanik dayanıklılığı sağlayan bakır veya alüminyum kablolarında kullanılır (Metwally, I. A., 2012). Uzun ömürlü ve dayanıklı bir performansa sahip bu kabloların kullanım alanı genelde tıbbi cihazlardır.

Silikon kauçuk, kimyasal direnç, yüksek sıcaklık, esneklik ve morötesi (UV) ışınlarına karşı dayanıklı oldukları için tercih edilir (Mehmood, B., ve ark. 2020). Otomotiv, fırın, metalurji ve diğer yüksek sıcaklık uygulamalarında yaygın olarak kullanılır.

TPE, termoplastik poliüretan (TPU), termoplastik poliolefin (TPO), Stiren-Etilen-Butilen-Stiren (SEBS) gibi farklı plastomer malzeme sınıflarına sahiptir. TPU, doğal bir esnekliğe sahiptir ve aşınmaya karşı direnç gösterir (Chen, X., ve ark 2021). Ayrıca birçok kimyasal maddeye karşı da dirençlidir. TPO, hafif ve düşük yoğunluğa sahip olduğu için kabloların ağırlığını azaltabilir (Li, Y., ve ark. 2022). SEBS, birçok kimyasala, UV ışınlarına ve hava koşullarına karşı dayanıklıdır (Zhang, P., ve ark. 2021). TPE ise düşük sıcaklıklarda bile esnekliğini koruyabilir ve hafiftir. Ayrıca yanma koşullarında düşük duman yoğunluğuna ve düşük toplam ısı salımına sahiptir. Aşağıda Tablo 2.3.'te izah edilen izolasyon çeşitlerine göre kablo çeşitlerinin görselleri ve özellikleri verilmiştir.

Tablo 2.3. Elektriksel kablo özellikleri ve izolasyon çeşitlerini

Görsel	Kablo Cinsi	Çalışma Sıcaklığı	Kısa devre sıcaklığı
	PVC izoleli, çok damarlı, bakır iletkenli	70°C	160°C (max. 5 sn.)
	PVC izoleli, kılıfsız, tek damarlı, bakır iletkenli	90°C	160°C (max. 5 sn.)
	XLPE izoleli, çok damarlı, alüminyum iletkenli	70°C	160°C (max. 5 sn.)
	XLPE izoleli, çok damarlı, bakır iletkenli	90°C	250°C (max. 5 sn.)
	EPR izoleli, zırhsız	85°C	250°C
	Çok damarlı, ince çok telli, bakır iletkenli, EPR izolasyonlu	90 °C	250 °C (max. 5 sn.)
	Kauçuk Kablolar	60°C	200 °C
	Bükülü Bakır Teller, TPE İzolasyonlu	80°C	?
	Çok telli, kalay kaplı bakır iletken, TPE izolasyon.	90°C	250°C

Tablo 2.3., farklı türdeki elektrik kablolarının özelliklerini ve izolasyon çeşitlerini, özellikle çalışma sıcaklıkları ve kısa devre sıcaklıklarını özetlemektedir. PVC izoleli kablolar, bakır iletkenli ve çok damarlı yapıları ile 70°C çalışma sıcaklığı ve 160°C'ye kadar olan kısa devre sıcaklıklarına dayanıklıdır. Aynı malzeme ile izole edilmiş kılıfsız, tek damarlı bakır iletkenli kablolar ise 90°C çalışma sıcaklığında işlev görebilmekte ve benzer şekilde 160°C'ye kadar kısa devre durumuna dayanabilmektedir. XLPE (Çapraz Bağlı Polietilen) izoleli kablolar, alüminyum veya bakır iletkenlerle üretilmekte olup, alüminyum iletkenli olanlar 70°C, bakır iletkenli olanlar ise 90°C çalışma sıcaklığında kullanılabilir. XLPE izoleli kabloların kısa devre sıcaklıkları ise 160°C ile 250°C arasında değişmektedir. EPR (Etilen Propilen Kauçuk) izoleli kablolar, 85°C ile 90°C arasında çalışma sıcaklıklarına sahip olup, 250°C'ye kadar kısa devre sıcaklığına dayanıklıdır. Kauçuk izoleli kablolar daha düşük, 60°C çalışma sıcaklığında işlev görmek ve 200°C kısa devre sıcaklığına kadar dayanıklıdır. TPE (Termoplastik Elastomer) izoleli kablolar ise 80°C ile 90°C arası çalışma sıcaklıklarında kullanılabilir ve bazıları 250°C'ye kadar kısa devre sıcaklığına dayanıklıdır. Bu çeşitlilik, elektrik kablolarının farklı uygulama

gereksinimlerine göre özel olarak tasarlanabildiğini ve çeşitli çalışma koşullarında güvenilir bir şekilde işlev görebildiğini göstermektedir.

2.6. Ticari ve endüstriyel tesislerde yangın algılama stratejileri

Ticari ve endüstriyel tesislerde yangın algılama stratejileri hem yasal açıdan hem de işveren açısından önem arz eder. Özellikle BYKHY Madde 78-79 ve 80’de ifade edildiği gibi, yangın kontrol panelinde ayrı bölgesel alarm göstergeleri oluşturularak izlenir. Çünkü bu tür tesislerde yangın riski yüksektir ve yangınların erken tespiti hem can kaybının hem de maddi kayıpların engellenmesine imkân verir. Dolayısıyla bu tür tesislerde tek algılama sistemi stratejisi yerine, çoklu algılama sistemi stratejisi yürütülür. Çoklu algılama stratejisinde, tespit edilen risk düzeyine göre ikili algılama, lineer duman ve ısı algılama, termal kamera sistemlerinin bir arada kullanılmasıyla, merkezi yangın algılama ve izleme sistemi kurulur. Bu kurulumlar bir yangın algılama stratejisi içinde, tesisin büyüklüğüne, yapısına ve kullanım amacına göre değişiklik gösterir. Dolayısıyla hem mevzuat hem de insani yaklaşım açısından özellikle endüstriyel tesislerde erken uyarı, hızlı müdahale ve güvenli tahliye için etkili bir yangın algılama stratejisi geliştirilmesi gerekir. Bu strateji sayesinde aslında teknoloji kullanılarak anlık yangın risk değerlendirme sistemi kurulmaktadır. Yangın riskinin değerlendirilmesi, bir tesisin yapısını, kullanımını, içerdiği malzemeleri ve olası yangın tehlikelerini analiz ederek algılama stratejilerinin oluşturulması ve işletilmesi üzerine gerçekleştirilir. Yangın algılama stratejileri ise çeşitli algılama teknolojilerinin etkinliğini ve uygulanabilirliğini değerlendirir. Gerçekleştirilen akademik çalışmalarda, bu teknolojilerin performansını, hassasiyetini, yanlış alarmlarını ve yangın tespitindeki etkinliğini inceleyerek, yangın algılama sistemlerinin geliştirilmesine olanak sağlar (Jafari, M. J., ve ark. 2020; MacLeod, J., 2020). Fakat klasik yangın algılama sistemleri genelde tavana montajı gerçekleştirilen dedektörlerle gerçekleştirilir. Dolayısıyla özellikle elektrik pano yangınlarına karşı yeni bir algılama sisteminin ihtiyaç olduğu düşünülmüş ve bu konuda çalışılmıştır.

2.7. Elektrik panosu yangın sebepleri

Elektrik panosu yangına neden olabilecek tehlikeleri barındırmaktadır. Bunlar, aşırı yüklenme, kısa devre, gevşek ve hasarlı bağlantı, kalitesiz malzeme kullanımı, uzun süreli ve bakım yapmadan kullanma ve diğer şartlardır. Aşırı yüklenme, normalden

daha fazla güç veya akımın yüklenmesi durumudur. Elektrik panoları bir proje kapsamında tasarlanır ve çekebileceği güç veya taşıyabileceği akım kapasitesi belirlenir. Birden fazla cihazın aynı devreyi kullanması, kapasiteyi aşan cihazların pano üzerinden beslenmesi ve anormal yük değişiklikleri aşırı yüklenmeye sebep olur (Li, Y., ve ark. 2022). Dolayısıyla pano ısınır, bileşenler zarar görür ve hatta yangın riskinin artar (Zhang, Y., ve ark. 2021).

Kısa devre, faz ve nötrün doğrudan temas etmesi sonucu oluşur ve akımının normalden çok daha yüksek miktarda akmasına neden olur. Kablodaki izolasyonun zarar görmesi, panoya bağlı veya panonun içindeki ekipman arızası ve fiziksel hasar kısa devreye sebep verir. Dolayısıyla yangın riski artar (Zhang, J., ve ark. 2021).

Gevşek veya hasarlı bağlantılar yüksek direnç oluşturarak, aşırı ısınma meydana getirir. Ayrıca kesikli veya dalgalı bir elektrik akımı oluşturur. Bu durum, gevşek bağlantı noktasında bileşen hasarı ve kıvılcım meydana getirir. Bu da panonun koruma mekanizmalarında işlevsizlik oluşturur ve yangın çıkartır (Zhang, J., ve ark. 2021).

Düşük malzeme kalitesi, izolasyonu zarar görmüş sorunlu kablolar meydana getirir. Dolayısıyla pano içinde kullanılmış düşük malzeme kalitesi olan bir kablo aşırı yüklenme veya kısa devre durumunda yeterli koruma sağlayamaz (Wu, Z., ve ark. 2020). Yukarıdaki kısımda anlatıldığı gibi kısa devre yangın sebeplerinden bir tanesidir.

Elektrik panosunun uzun süreli kullanımı ise aşınma, yıpranma, kablolarda yorgunluk, kesicilerde hata payının artması ve bakım eksiklikleri meydana getirir (Ong, N. A. F. M. N., ve ark. 2022). Bakımların ve kablo izolasyon testlerin periyodik kontrolü yapılmalıdır. İzolasyon direnç, dielektrik, sıcaklık ve mekanik darbe testleri ile ölçümler gerçekleştirilerek kontroller tamamlanır. Ertelenen veya geciktirilen kontroller yangın riskini arttırır.


Ekipman arızaları ve bileşenleri, panolarda yangın riskini arttırır. Bu tür arızalar, kontrolsüz aşırı akım, kısa devre ve aşırı ısınma durumlarını arttıracığı için yangın riski artar.

Ayrıca yukarıdaki tüm yangın riskini arttıran koşullardan hariç, toz ve kir (Juarez-Lopez, J. M., ve ark. 2023), yetersiz soğutma, dış etkiler, kötü hava şartları, uygun olmayan ortamlarda yerleşim yeri seçimi, eğitimsiz personel, su ve nem sızıntıları,

kalitesiz işçilik, illegal bağlantılar, kimyasal maddeler elektromanyetik alanlar, sabotaj ve doğal afetler yangın riskini arttıran unsurlardır.

2.8. Elektrik panolarında veri analitiği kullanarak yangın riskinin tahmini

Yangınların veri analitiği aracılığıyla tahmin edilmesi, yangın riskinin öngörülmesinde daha proaktif bir yaklaşım sağlar (Zhang, Y., ve ark. 2021). Veri analitiği ile elektrik panolarındaki çeşitli parametreleri ve çevresel koşullar izlenerek yangın olasılıkları değerlendirilebilir. Bu tez kapsamında, ML yöntemi ile veri analitiği üzerinde çalışılmıştır. Bu amaçla, veriler, çeşitli ML algoritmaları kullanılarak analiz edilmiştir ve elektrik panosundaki koşulların normal veya yangın başlangıç aşamasına doğru ilerleyen süreci tespit etmek hedeflenmektedir. Aşağıdaki Şekil 2.8’de ısı salınım grafiği görseli verilmiştir.



Şekil 2.8. Isı salınım grafiği. (Alarifi, A. A. S.,ve ark. 2016)

Çalışmada, Şekil.2.8'de gösterilen Stage kelimesine karşılık olarak Sınıf kelimesi kullanılmıştır. Sınıf1 (S1) tutuşma öncesi koşulları (içten içe yanan) ifade eder ve Sınıf2 (S2) ise iyi bir alev gelişimi gibi tutuşma flaş aşaması koşullarını temsil eder. Sınıf3 (S3) tamamen gelişmiş yangın aşaması koşullarını temsil ederken, Sınıf4 (S4) ise yangın sonrası durumları temsil eder. Bu koşullardan hariç normal koşullar için (N) kullanılmıştır. Bu çalışmada, bu koşulları elde etme amaçlı IoT ile veriler toplanmış ve ML ile veriler analiz edilmiştir.

2.9. Nesnelerin İnterneti

IoT temelde fiziksel nesnelerin internete bağlanarak çevreleriyle ve birbirleriyle iletişim kurmasıdır (Rezaee, N. Ve ark., 2023). IoT, akıllı ev uygulamaları, akıllı gözetim sistemleri ve savunma ve güvenlik sistemleri gibi birçok alanda kullanılmakta

olup (Sert, S. A. 2023), bilgisayar, elektrik ve elektronik (Ayvaz, B. ve ark., 2023), endüstri mühendislikleri, iletişim teknolojileri (Karaman, S. 2023). , matematik, istatistik ve veri bilimi (Yılmaz, F. ve ark., 2023) gibi çeşitli disiplinleri içinde barındırmaktadır. IoT’de kullanılan donanım ve sensörler enerji verimliliği ve düşük güç tüketimi (Kaya, M. S. ve ark., 2023), güvenli ve hassas veri toplama kabiliyeti ve stabil bağlantı protokolleri (Türker, G. F. ve ark., 2023) kurulmasında önemli aşamalar kaydetmiştir. Büyük miktarda gelen verilerin depolanması ve analiz edilmesi bulut bilişim tabanlı çalışma, ML ve yapay zekâ gibi alanları desteklemesi avantaj olarak görülmektedir (Aydın, N., 2023).

IoT’de nesneler, yazılımlar, sensörler, ağ bağlantıları, kablosuz iletişim protokolleri, veri işleme, depolama, güvenlik ve gizlilik özellikleri ile donatılır (Gündüz, M. Z. ve ark., 2018). Temel amaç, fiziksel dünya ile dijital platform arasında bağlantı oluşturarak, veri toplamak, işlemek ve güvenli şekilde paylaşmaktır. IoT akademik araştırmaların da odak noktalarından biridir. Endüstriyel tesisler, akıllı şehirler (Urhan, O. ve ark., 2023), sağlık hizmetleri (Aydoğan, İ. ve ark., 2023) ve enerji (Sinoplu, M. ve ark., 2023) gibi alanlarda IoT’nin kullanımı üzerinde akademik çalışmalar yapıldığı görülmüştür. IoT, özellikleri genellikle hazır olarak sunulur. Fakat bu özellikler kullanıcı tarafından da geliştirilebilir. Elektrik kaynaklı yangınlarda özellikle pano yangınlarında yangın meydana gelmeden önce hızlı ve erken tespit imkânı IoT destekli bir yapı ile gerçekleştirilebileceği düşünülmektedir.

2.9.1. Elektrik panolarındaki yangın algılama sistemlerinin uzaktan izlenmesi

Yangın algılama sistemlerinin uzaktan izlenmesi ve erken uyarı sistemlerinin, yangın güvenliği alanında kritik bir rol oynaması, literatürde geniş kapsamlı bir şekilde tartışılmaktadır. Bu sistemlerin, elektrik panolarında meydana gelebilecek yangınların erken tespiti ve hızlı müdahale edilmesi açısından önemli olduğu görülmüştür (Xu, H., ve ark., 2019; He, X., 2022). Araştırmalar, bu sistemlerin, bir dizi sensör, izleme paneli ve kablolu veya kablosuz veri iletişimi istasyonu gibi bileşenlerden oluştuğunu göstermektedir (Roque, G., ve ark., 2020). Uzaktan izleme özelliği, yangın güvenliği sorumlularının bir kontrol merkezinden veya mobil cihazlardan, yangın algılama sistemlerinin durumunu gerçek zamanlı olarak izlemelerine olanak tanır. Bu, potansiyel yangın risklerinin hızlı bir şekilde belirlenmesini ve gerekli önlemlerin alınmasını sağlar.

Yangın güvenliği literatüründe yapılan çalışmalar, bu tür sistemlerin bir dizi avantajını ve dezavantajını ortaya koymuştur. Örneğin, bu sistemlerin maliyet tasarrufu sağladığı, düşük bakım gereksinimine sahip olduğu ve hızlı olay yanıt sürelerine sahip olduğu belirtilmektedir (Brito, T., ve ark., 2020; Ramana Karumanchi, V., 2021; Baek, J., 2021). Ancak, dağınık yapılarından kaynaklanan bazı dezavantajlar da vardır. Özellikle büyük tesislerde veya karmaşık yapıların olduğu alanlarda, sistemlerin yönetimi ve entegrasyonu zor olabilir.


Bu bağlamda, yapılan çalışmalar, yangın güvenliği alanında uzaktan izleme ve erken uyarı sistemlerinin önemini vurgulamaktadır. Bu durum yangın güvenliği uygulamaları ve teknolojileri üzerine karar verme süreçlerinde önemli bir rol oynamaktadır.

Ayrıca, sensör tabanlı IoT gibi yeni teknolojilerin, bina yangın güvenliğini ve acil durum kurtarma verimliliğini artırma potansiyeline sahip olduğu belirtilmektedir (Chen, H. ve ark., 2021). IoT'nin yangın algılama sistemlerine entegrasyonu, yangın tehlikesini daha hızlı ve etkili bir şekilde tespit etmeyi, alarm verme sürecini iyileştirmeyi ve yangınla mücadele sürecini optimize etmeye yönelik hizmet sunmaktadır (Zarpeľão, B. B. ve ark., 2017; Nižetić, S. ve ark., 2020). IoT sensörler, çevredeki değişiklikleri sürekli olarak izler ve yangın belirtilerini algılayarak hızlı bir şekilde merkezi birime (Damaševićus, R. ve ark., 2023) veya bulut tabanlı bir hizmete iletir (Mahbub, M. ve ark., 2021). Bu sayede uzaktan izleme ve kontrol mümkün hale gelir. Ayrıca, gelen veriler analiz edilerek koşulların gelecekteki eğilimleri belirlenebilir. Cihaz performansı izlemeye ve bakım gerektiren durumları tanımlamaya yardımcı olarak sistemlerin güvenilirliğini artırır, olası arızaların önlenmesine ve maliyetlerin düşürülmesine katkı sağlar (Ayvaz, S. ve ark., 2021). Son olarak, kullanılan sensörlerin düşük güç tüketimi, enerji verimliliğini artırır. Yangın algılama ve ihbar verme sisteminin IoT ile entegrasyonu, otomatik olarak büyük veri toplayarak hızlı tepki verme avantajı sunmaktadır (Cui, F., 2020). Benzer koşullar elektrik panolarında yangın algılama için de geçerlidir.

2.10. Makine Öğrenimi

ML, algoritmalar ve istatistiksel modeller yardımıyla bilgisayarların deneyimlerden öğrenerek belirli görevleri yerine getirmesini sağlayan bir yapay zekâ dalıdır. Temelde amaç, geçmiş verilerden öğrenerek yeni girdiler üzerinde tahmin yapma, sınıflandırma

gibi görevleri gerçekleştirebilecek algoritmalar geliştirmektir (Sarailidis, G., ve ark. 2023). ML denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olarak üç farklı ana kategoriye ayrılmaktadır. Diğer bir dördüncü kategori ise ilk iki öğrenme kategorisinin arsında kalan yarı denetimli öğrenme kategorisidir (Alkhaleel, B. A. 2023; Xu, Z., ve ark. 2021). ML kategorilerini gösterir yapı aşağıdaki Şekil 2.9.'da verilmiştir.



Şekil 2.9. Makine öğrenimi (ML) yöntemleri (Xu, Z., & Saleh, J. H., 2021).

Şekil 2.9.'da verilen kategorilere ait yöntemler çok çeşitli uygulamalar için kullanılmakta olup, görsel ve ses tanıma, doğal dil işleme, tıbbi tanı ve finansal pazar analizi gibi alanlarda sıklıkla kullanılmaktadır.

Denetimli öğrenme, belirli bir sonucu tahmin etmek veya sınıflandırmak amacıyla kullanılan bir öğrenme türüdür (Jiang, T., ve ark. 2020). Bu sebeple, genelde tahmin görevlerini tanımlamak için kullanılır. Denetimli öğrenme modelleri sağlık hizmetleri (Gu, X., ve ark. 2023), finansal hizmetler (Lei, X., ve ark. 2022), görüntü ve ses işleme (Tripathi, A. M., ve ark. 2021; Aljuaid, A., ve ark. 2022), doğal dil işleme (Nagarhalli, T. P., ve ark. 2022), üretim ve endüstriyel uygulamalar (Wuest, T., ve ark. 2014), genetik (Abdulqader, D. M., ve ark. 2020) ve çevre/yer bilimleri (Tahmasebi, P., ve ark. 2020) alanlarında kullanılmaktadır . Denetimli öğrenme kendi içerisinde sınıflandırma ve regresyon olarak iki alt kategoriye ayrılır (Nasteski, V., 2017). Sınıflandırma, verilerin genellikle belirli bir amaç için kategoriler halinde toplandığını tanımlar (Kadhim, A. I. 2019). Sınıflandırma algoritmaları içinde en bilinen olanları KA, Sinir Ağı, K-en yakın komşular ve SVM, GNB, Rastgele Orman, Lojistik regresyon sınıflandırma, Gauss Süreç Sınıflandırıcısı (GPC), gibi algoritmalar (Bhavsar, H., ve ark. 2012; Choudhary, R., ve ark. 2017; Crisci, C., ve ark. 2012;

Sharpe, C., ve ark. 2019; Arabameri, A., ve ark., 2021). Regresyon ise bir veri kümesindeki bağımsız değişkenlerle bağımlı değişken arasındaki sürekli sonuçların tahmini ilişkisini modellemek için kullanılır (Xu, X., ve ark. 2022; Jiang, T., ve ark. 2020). Regresyon, algoritmaları içinde bilinir olanlar Destek Vektör, K-en yakın komşular, Doğrusal, Polinom, Lasso, Tepe, Lojistik, KA, Rastgele Orman gibi algoritmalar yer alır (Bonaccorso, G., 2018; Doan, T., ve ark. 2015). Aşağıdaki Tablo 2.4.'te denetimli öğrenmetürleri ve algoritma çeşitleri verilmiştir.

Tablo 2.4. Denetimli öğrenme uygulama türleri ve algoritmaları.

Yöntem	Çıktı Türü	Tahmin Problem	Çıktı Değerleri	Performans Ölçütleri	Algoritmalar
Sınıflandırma	Kategorik veya sınıflandırılabilir yapı	Veri örneğini belirli bir sınıfa atamak veya sınıflandırmak	Sınıf etiketleri veya her bir sınıfa ait olasılık	Hassasiyet, geri çağırma, F1 skoru gibi sınıflandırma özel performans ölçütleri	Karar Ağaçları, Rastgele Orman, Destek Vektör Makineleri, K-En Yakın Komşu, Yapay Sinir Ağları, Naive Bayes, Gauss Süreç Sınıflandırıcısı, Lojistik Regresyon Sınıflandırma
Regresyon	Sürekli sayısal değer	Bağımsız değişkenlerin bir fonksiyonu olarak bağımlı bir değişkenin tahmini	Bir aralıkta veya belirli bir değer kümesinde	Ortalama kare hata, ortalama mutlak hata gibi regresyon özel performans ölçütleri	Karar Ağaçları, Rastgele Orman, Lineer, Polinom, Destek Vektör, K-En Yakın Komşu, Yapay Sinir Ağları,

Tablo 2.4., denetimli öğrenme yaklaşımlarının temel uygulama türlerini, bu uygulamalarda kullanılan algoritmaları, çıktı türlerini, tahmin problemlerini, çıktı değerlerini ve performans ölçütlerini özetlemektedir. Denetimli öğrenme, önceden etiketlenmiş veri kümeleri üzerinde modelin eğitildiği ve bu modele dayanarak yeni

veri örneklerine tahminler yapma yeteneğinin kazandırıldığı bir ML yaklaşımıdır. Sınıflandırma yöntemi, veri örneklerini belirli sınıflara atayan kategorik çıktılar üretir ve performansı hassasiyet, geri çağırma, F1 skoru gibi sınıflandırmaya özgü metriklerle ölçülür. Bu yöntemde KA, Rastgele Orman, SVM gibi algoritmalar yaygın olarak kullanılır. Regresyon yöntemi ise, bağımsız değişkenlerin bir fonksiyonu olarak sürekli sayısal değerlerin tahmin edilmesini sağlar; burada ortalama kare hatası ve ortalama mutlak hata gibi regresyona özgü performans ölçütleri önem kazanır. KA ve Yapay Sinir Ağları gibi algoritmalar bu alanda sıkça tercih edilir. Her iki yaklaşım da denetimli öğrenmenin uygulama alanının genişliğini ve ML modellerinin çeşitli problemlere uygun çözümler üretebilme kapasitesini göstermektedir.

Denetimsiz öğrenme, veriye kendi kendine keşif yapma yeteneği sağlayan, etiketli veri kullanmayan, eğitimsiz öğrenme türüdür (Schmarje, L., ve ark. 2021; Hastie, T., ve ark. 2009). Denetimsiz öğrenme, etiketlenmemiş veri kümeleri üzerinde çalışarak gizli yapıları, desenleri bulma sorumluluğuna sahiptir (Dike, H. U., ve ark. 2021). Bu öğrenme yöntemi, sosyal medya üzerinden pazarlama (Sánchez-Hernández, G., ve ark. 2013), tıp (Eckhardt, C. M., ve ark. 2023), görüntü tanıma (Wang, Y., ve ark. 2016), finans (Hoang, D., ve ark. 2023), siber güvenlik (Alom, M. Z., ve ark. 2017), üretim ve bakım (Wocker, M., ve ark., 2020) gibi birçok alanda kullanılır. Denetimsiz öğrenme, üç ana kategori altında incelenir. Bunlar kümeleme, boyut indirgeme ve birliktelik yöntemleridir (Althuwaynee, O. F., ve ark. 2021; Mahadevkar, S. V., ve ark. 2022). Aşağıdaki Tablo 2.5.'te denetimsiz öğrenme uygulama türleri ve algoritmaları veirlmiştir.

Tablo 2.5. Denetimsiz öğrenme uygulama türleri ve algoritmaları.

	Amaç	Kullanım Alanı	Algoritma
Kümeleme	Verileri benzerliklerine göre kümelemek	Pazarlama, müşteri, görüntü tanıma,	K-ortalama, Hiyerarşik kümeleme
Boyut İndirgeme	Yükse veri kümelerini, düşük boyutlu kümeye çevirmek	Veri görselleştirme ve analiz, model eğitimi hızlandırma.	PCA (Principal Component Analysis), t-SNE (t-Distributed Stochastic Neighbor Embedding).
Birliktelik Kuralları	Veriler arasındaki ilişkileri tanımlamak.	Market sepet analizi, öneri sistemleri, satış stratejileri	Apriori, FP-Growth.

Tablo 2.5., denetimsiz öğrenme yönteminin çeşitli uygulama türlerini, bu türlerin amaçlarını, kullanım alanlarını ve kullanılan özel algoritmaları özetlemektedir. Denetimsiz öğrenme, etiketlenmemiş veriler üzerinde örüntü ve ilişkileri keşfetmeye odaklanan bir ML yaklaşımıdır. Kümeleme, veri noktalarını benzerliklerine göre gruplara ayırmayı amaçlar. Bu süreçte K-ortalama ve Hiyerarşik kümeleme algoritmaları yaygın olarak kullanılır. Boyut indirgeme, yüksek boyutlu veri kümelerini daha az boyutlu, yönetilebilir formata dönüştürerek veri görselleştirme ve analizini kolaylaştırır ve model eğitim süreçlerini hızlandırır; bu amaçla PCA ve t-SNE gibi teknikler tercih edilir. Birliktelik kuralları, veri öğeleri arasındaki ilişkileri ve düzenlilikleri tanımlamak için kullanılır; özellikle analiz, öneri sistemleri ve satış stratejileri geliştirmede Apriori ve FP-Growth algoritmaları ön plana çıkar. Bu uygulama türleri ve algoritmalar, denetimsiz öğrenmenin, verilerden anlamlı bilgiler çıkarma ve karar verme süreçlerini desteklemede kritik bir rol oynar.

Yarı denetimli öğrenme hem etiketli hem de etiketsiz verileri kullanarak bir model eğitmek için kullanılan, denetimli ve denetimsiz öğrenme türlerinin bir karışımıdır (Forestier, G., ve ark. 2016; Pise, N. N., ve ark. 2008). Bu yöntem birçok farklı alanda kullanılır. Bunlar arasında görüntü tanıma ve sınıflandırma (Guillaumin, M., ve ark. 2010), doğal dil işleme (Hagberg, E., ve ark. 2022), hassas veri kategorileştirme (Mo, M., ve ark. 2010) gibi alanlar yer alır.

Takviyeli öğrenme, ML dallarından biridir ve birçok alanda kullanılmaktadır (Kayhan, B. M., ve ark. 2023). Birkaç örnek olarak bu alanlar arasında, çevrimiçi çok oyunculu oyunlar (Xin, X., ve ark. 2022), robot eğitimi (Ibarz, J., ve ark. 2021), otonom sürüş (Kiran, B. R., ve ark. 2021; Shan, Y., ve ark. 2020) ve üretim ile operasyon yönetimi süreçleri (Kayhan, B. M., ve ark. 2023) yer almaktadır.

Tablo 2.6. Makine Öğrenimi (ML) Türlerinin Karşılaştırması

Tür	Avantajlar	Dezavantajlar
Denetimli Öğrenme	Belirli sonuçlara doğrudan ulaşma	Etiketlenmiş veri gereksinimi
Denetimsiz Öğrenme	Etiketlenmemiş veri kullanabilme	Sonuçların yorumlanması zor olabilir
Yarı Denetimli Öğrenme	Hem etiketli hem de etiketlenmemiş veriyi kullanabilme	Etiketli verinin eksikliği
Takviyeli Öğrenme	Etkileşim içeren ortamlarda başarılı	Eğitim süreci uzun ve maliyetlidir

Tablo 2.6., farklı ML türlerini, her birinin avantajlarını ve dezavantajlarını karşılaştırmalı olarak sunmaktadır. Denetimli öğrenme, belirli sonuçlara doğrudan ulaşma avantajına sahip olmasına rağmen, etiketlenmiş veri gereksinimi gibi bir dezavantaja sahiptir. Bu, modelin eğitilmesi için önceden sınıflandırılmış veya etiketlenmiş veri kümelerine ihtiyaç duyulduğu anlamına gelir. Denetimsiz öğrenme, etiketlenmemiş verilerle çalışabilme esnekliği sunarken, elde edilen sonuçların yorumlanmasının zor olabileceği bir dezavantaja sahiptir, bu da doğrudan açık sonuçlara ulaşmayı güçleştirir. Yarı denetimli öğrenme hem etiketli hem de etiketlenmemiş verileri kullanabilme avantajını barındırırken, etiketli verinin eksikliği dezavantajıyla karşı karşıyadır; bu yöntem, sınırlı etiketli veri mevcut olduğunda idealdir. Takviyeli öğrenme, etkileşimli ortamlarda modelin kendini geliştirmesi için güçlü bir yöntem sunarken, eğitim sürecinin uzun ve maliyetli olması gibi önemli bir dezavantaja sahiptir. Bu türler arasındaki karşılaştırma, her bir ML yaklaşımının farklı ihtiyaç ve senaryolar için nasıl benzersiz avantajlar ve zorluklar sunduğunu göstermektedir.

2.10.1. Karar Ağaçları Algoritması

Denetimli öğrenme kategorisinde yer alan karar ağaçları (KA) algoritması, yüksek boyutlu ve karmaşık verilerden kalıpları otomatik olarak çıkarmak için yaygın olarak kullanılan bir tür ML yöntemidir (Sarailidis, G., ve ark. 2023). Ağaç yapısı ile temsil edilen ve hiyerarşik bir yapıya sahip olan KA kök, düğüm, yaprak ve dallardan oluşur. Bu yapıda kök başlangıcı, bir iç düğüm özellik testini, bir dal özellik değerini ve bir yaprak düğüm sınıf etiketini ya da tahmini ifade eder (Shrivastava, A., ve ark. 2023). Kısaca her iç düğüm, iki alternatif arasında tercih yapmayı önerirken, her yaprak düğüm ise bir sınıflandırmayı veya kararı belirtir (Tabassum, H., ve ark. 2023). Aşağıdaki Şekil 2.10'da karar ağaçlarının görseli verilmiştir.



Şekil 2.10. Karar ağaçları örnek gösterimi (Kaur, S., ve ark. 2023)

Şekil 2.10.'da da görülebileceği gibi bir KA verileri sınıflandırmak veya bir çıktı değerini tahmin etmek için karar noktaları ve dallanmalardan oluşan ağaç benzeri bir yapı kullanır. KA algoritmaları, çeşitli avantajlara sahiptir. Bunlar arasında özellikle yorumlanabilirlik, kullanım kolaylığı ve hem kategorik hem de sürekli özellikleri ele alma yeteneği öne çıkar (Kumar, P., ve ark. 2023). Fakat KA'nın bazı kısıtlamaları bulunur. Bunlar arasında, ağaç yapısı diğer algoritmalara göre yorumlamayı daha az verimli yapar. Ayrıca parametrik verilerle parametrik olmayan verileri eşleştirmek için bir uzman değerlendirici gerektirir (Rezapour, M., ve ark. 2020). Literatür incelendiğinde, bir çalışmada orman yangınları tahmininin, KA ve diğer algoritmalarla yapıldığı görülmüştür. Bu çalışmada, güçlendirilmiş KA metodunun %78 oranı ile en güçlü tahmini gerçekleştirdiği ve erken tahmin için görüntü ve meteorolojik koşulları ortaklaşa değerlendiren IoT destekli bir sistemin kullanımı tavsiye edilmiştir (Sharma, R., ve ark. 2020). Farklı bir çalışmada ise konut yangınlarında KA, diskriminant analizi, destek vektör makineleri, en yakın komşular ve topluluk sınıflandırma algoritmaları destekli yapay sinir ağı modeli önerilmiştir. Yangın konumunu tahmin etmede, modelin genel olarak %82 başarı sağladığı paylaşılmıştır. Matlab programında sunulan KA algoritmalarından olan, orta ağaç ve güçlendirilmiş topluluk KA algoritmalarının %64 doğrulukla sınıflandırmayı en başarılı şekilde gerçekleştirdiği paylaşılmıştır (Ouache, R., ve ark. 2022). SVM, verilerin dağıtımına duyarlıdır. Bu durum, veri dağıtımını önceden bilmesi gereken diğer istatistiksel tekniklerle karşılaştırıldığında daha avantaj sağlamaktadır (Sheykhmousa, M., ve ark. 2020). İnce ağaç modeli, Matlab programında kullanılan karar ağacı algoritmasının bir çeşididir (Asante-Okyere, S., ve ark. 2022) ve veri kümesindeki detayları yakalamak için derin ve yoğun dallanmalar kullanır, bu da daha detaylı öğrenmeye olanak tanır. Ancak, bu özellik aşırı uyum sağlamasına neden olabilir.

2.10.2. Destek vektör makinesi algoritması

Destek Vektör Makinesi (SVM), 1990'lı yıllarda Vladimir Vapnik tarafından geliştirilen, istatistiksel öğrenme teorisine dayanmaktadır (Basha ve Rajput, 2019). Sınıflandırma ve regresyon problemlerinde tercih edilir. Özellikle doğrusal ve doğrusal olmayan veri sınıflandırma problemlerinde kullanılır (Ghosh, S., ve ark. 2019). SVM, matematiksel bir temele sahiptir, genelleme kapasitesi yüksektir ve gerçek uygulamalarda mükemmel sayılabilecek başarı ile sonuç vermiştir (Chandra, M. A., ve ark. 2021). SVM, iki sınıfı maksimum marjla en iyi şekilde ayıran hiper

düzlemi oluşturmak için kullanılır. Optimum ayırıcı hiper düzleme en yakın olan ve daha geniş bir kenar boşluğuna sahip olan veri noktaları, sınıflandırılması en zor olanlardır (Frunza, M. C., 2016). Bu koşulda, SVM sınıflandırma görevinin karmaşıklığı, destek vektörlerinin sayısına bağlıdır. Kullanılan destek vektörlerinin sayısı, orijinal veri kümesine göre belirlenir ve genellikle eğitim veri kümesinin yarısı kadardır (Awad, M., ve ark. 2015). Bu durum eğitim süresini olumsuz etkilemektedir. SVM için kullanılacak ÖÖE algoritmanın dezavantajlarından kaçınmak için entegre edilir (Cervantes, J., ve ark. 2020). Literatür taraması sonucunda, Chen ve arkadaşlarının (2022) yaptığı çalışmada, yangın tespiti ve erken uyarı için SVM algoritmasının, Rastgele Orman (RF), K-ortalama ve Yapay Sinir Ağı (YSA) gibi diğer algoritmalarla karşılaştırıldığında daha etkili performans sergilediği belirlenmiştir. Farklı bir çalışmada yangın görüntülerinin incelenmesinde SVM kullanılmıştır. Özellik seçimi yaklaşımları kullanılarak hesaplama maliyeti en aza indirilmiş ve yangın ile yangın olmayan piksellerin sınıflandırılması gerçekleştirilmiştir. Modelin performansı %96,21 doğruluk, %94,42 hassasiyet, %97,99 özgüllük, %97,91 kesinlik, %94,42 geri çağırma, %96,13 f-ölçütü ve %96,19 g-ortalama sonuçları paylaşılmıştır (Harkat, H., ve ark. 2023).

2.10.3. Gauss naive bayes sınıflandırıcı algoritması

ML’de kullanışlı sınıflandırma tekniklerinden biri olan Gaussian Naive Bayes (GNB) öğrenme ve test etme sürecine sahip üretken model tabanlı bir algoritmadır (Jahromi, A. H., ve ark. 2017). Naive Bayes sınıflandırıcısı, Bayes teoreminin uygulanmasına dayalı, kolay ve basit bir olasılıksal sınıflandırıcı olup, her nitelik değişkenini bağımsız değişken olarak kabul eder (Kamel, H., ve ark. 2019). Bu sınıflandırıcı, çoklu sınıflı tahminler gerektiren problemlerde uygulanmasına rağmen, özellik bağımsızlığı varsayımından kaynaklanan hızlı işleyişi ve yüksek doğruluk avantajıdır (Naiem, S., ve ark. 2023). Fakat dezavantaj olarak, performansı olumsuz etkileyebilecek ilgisiz özelliklere karşı duyarlılığıdır (Sen, K., ve ark. 2023). Ayrıca bu sınıflandırıcının bağımsız olduğu varsayılmaktadır. Ancak yaygın olarak kullanılan özelliklerinin birbirinden bağımsız olması zordur (Che, Y. 2023). Son olarak küçük veri kümelerinde iyi çalışmaz ve performans düşük kalır (Arora, A., ve ark. 2022). Bu algoritma, deneyime dayalı olarak bir olayın meydana gelme olasılığını Formül 2.1’e göre hesaplar (Goswami, 2020).

$$P(cx) = \frac{P(xc)*P(c)}{P(x)} \quad (2.1)$$

Burada $P(cx)$ c sınıfına ait x'in olasılık değerini, $P(xc)$ x'in c sınıfı için eğitim verisindeki gerçek olasılık değerini, $P(c)$ x'in eğitimdeki gerçek olasılık değerini temsil etmektedir. $P(x)$ ise eğitim verilerinden hesaplanan gerçek olasılık değerini temsil etmektedir (Goswami, 2020). Literatür incelendiğinde, bir çalışmada fourier spektrum analizini kullanılarak yangın algılama teknoloji üzerinde çalışıldığı görülmüştür. Bu çalışmada SVM ve GNB algoritmaları ile iki farklı sınıflandırma kullanıldığı ve iki sınıflandırmanın %95'in üzerinde başarı sağladığı görülmüştür. Önerilen sistemin, 50 metre uzaklıktan mor ötesi ışığı analiz ederek doğru sınıflandırma ile sonuç verdiğinin bilgisi paylaşılmıştır (Truong, C. T., ve ark. 2023). Farklı bir çalışmada, modern güç sistemlerinde hata teşhisi üzerinde veri madenciliği kullanılarak, GNB tabanlı analiz sınıflandırma yöntemi kullanılmıştır. Çalışmada GNB'den hariç ayrıca SVM, K-en yakın komşu, KA, rastgele orman ve uyarlanabilir arttırıcı sınıflandırma algoritmaları kullanılmıştır. Modern güç sistemlerinde hata teşhisi geç yapıldığı veya hiç yapılmadığı zaman çıkan yangının yayılabileceği ve ölümcül olabileceği bildirilmiştir. Çalışma sonuçlarında Gaussian Naïve Bayes algoritmasının %99,66 doğruluk ile en yüksek başarıya sahip olduğu bilgisi paylaşılmıştır. Daha sonra sırasıyla K-en yakın komşu (%98,62), rastgele orman (%98,61), KA (%98,3), uyarlanabilir arttırıcı sınıflandırma (%96,59) ve SVM (%96,51) doğruluk ile başarıya ulaştığı bilgisi verilmiştir (Venkata, P., ve ark. 2022).

2.10.4. Gauss süreç sınıflandırıcısı algoritması

Christopher K. I. Williams tarafından 1998'de "Sonsuz Sinir Ağları ile Hesaplama" çalışmasında ortaya atılan Gauss Süreç Sınıflandırıcısı (GPC), parametrik olmayan bir olasılıksal sınıflandırma modelidir (Williams, C. K., 1998). Bu model, örnek verileri doğrudan kullanabilme yeteneğiyle dikkat çeker ve teorik dağılımdaki özellik parametrelerinin tahminlerine gerek duymaz (Qin, Z., ve ark., 2011). Tahmin olasılıkları aşağıdaki Formül 2.2.'ye göre hesaplanır


$$p(f^*|y, X, x^*) = \int p(f^*|F, x^*) p(F|y, X) dF. \quad (2.2)$$

Bu formül, tahmin edilmek istenen hedef değişkenin, belirli bir giriş verisi (x^*) ve veri kümesi (X) dikkate alındığında, tahmini dağılımını ifade eder. $p(f^*|y, X, x^*)$ hedef değişkenin x^* giriş verisi ve mevcut veri kümesi X 'e dayanarak tahmin edilen

dağılımını temsil eder. $p(f^*|F, x^*)$ ise hedef değişkenin x^* giriş verisi ve F belirsizliklerin kümesi dikkate alındığında, hedef değişkenin dağılımını ifade eder. $p(F|y, X)$ latent değişkenler kümesinin veri seti ve gözlemlerden yola çıkarak dağılımını temsil eder. Literatür incelendiğinde, akıllı yangın algılama sistemi üzerinde yapılan bir çalışmada GSS algoritmasının kullanıldığı görülmüştür. Sistemde, görüntüden çıkarılan özelliklere dayalı yangın kararının verilmesi için görüntü sınıflandırmasında GSS önerilmiştir. GSS ile elde edilen sonuçlarda, açık alev görüntülerinde %96,97, için için yanan görüntülerinde %97,37 ve yanma olmayan görüntülerde %100 başarı sağlanmıştır (Wan, X., ve ark. 2022).

2.10.5. Rastgele Orman Algoritması

Rastgele Orman algoritması, sınıflandırma ve regresyon problemlerini çözmek için kullanılan, yüksek doğruluk sağlayan bir ML algoritmasıdır ve birçok KA'nın bir araya gelmesiyle oluşturulur (Speiser, J. L., ve ark. 2019). Her ağaç kendi tahminini yapar, sonra bu tahminlerin ortalaması alınır ve sonuç tahmini yapılır. Etiketlenmemiş örnekler için sınıf etiketini belirlemede, birden fazla sınıflandırıcıyı bir araya getiren bir topluluk yaklaşımını kullanır (More, A. S., ve ark. 2017). Bu yöntemin avantajları arasında, hızlı olması ve paralel işlem yapabilme kabiliyeti yer alırken, dezavantaj olarak KA oluşturma kuralları sabit olduğu için, aşırı uyum riski bulunur (Feng, W., ve ark. 2020). Ayrıca, yüksek boyutlu ve dengesiz veri kümeleri, algoritmanın performansında düşüşe neden olabilir. Literatür incelendiğinde, uydu görüntülerinden yanmış alanların analizinde rastgele orman algoritmasının sınıflandırma amaçlı kullanıldığı bir çalışmada görülmüştür. Çalışma, ilgili yıllar ve bölgelerde yangın alanlarının, tropikal bölgelerden elde edilen sonuçların kuzey ve ılıman bölgelerden elde edilen sonuçlara göre daha düşük hatalara sahip olduğunu gösterdi (Ramo, R., ve ark. 2017). Aşağıdaki Şekil 2.11.'de rastgele orman algoritmasının örnek yapısı paylaşılmıştır.



Şekil 2.11. Rastgele orman algoritması örnek gösterimi (Lakshmanaprabu, S. K., ve ark. 2019)

Şekil 2.11. birden fazla KA birleşmesinden meydana gelen rastgele orman algoritmasının göstermektedir. Şekil2.11.'de de görülebileceği gibi birçok KA'nın sonuçlarının bir araya getirilmesi esasına dayanmaktadır.

2.10.6. Lojistik regresyon sınıflandırma algoritması

Lojistik regresyon (LR) sınıflandırması, istatistiksel veri analizinde bir veya birden fazla bağımsız değişken ile bağımlı değişken arasındaki ilişkileri belirleyerek sınıflandırma problemlerini çözmek için kullanılan bir yöntemdir (Thabtah, F., ve ark. 2019). Girdi verilerini kullanarak, belirli bir sonucun olasılığını tahmin etmeye çalışır. İşleyişte, doğrusal regresyon sonuçlarını belirli bir sigmoid fonksiyonuna göre sınırlayarak ve akabinde belirli bir eşik değeri kullanarak sınıflandırma yapar (Shah, K., ve ark. 2020). Bu algoritmanın avantajları arasında basit ve hızlı olması, yanlış sınıflandırmaları en aza indirmesi yer alır. Fakat aşırı öğrenmeye karşı duyarlı olması dezavantajdır. Literatür incelendiğinde, orman yangınlarını algılamada bu algoritmanın ve SVM, GNB, RA ve KA algoritmalarının yangın ve yangın olmayan görüntüleri sınıflandırmada kullanıldığı görülmüştür. 3500 farklı görüntü üzerinden elde edilen sonuçlarda lojistik regresyon sınıflandırma (%96,47) ve rastgele orman (%95,49) algoritmalarının en yüksek doğruluğa sahip olduğu, Naïve Bayes (%84,54) ve KA (%87,46) algoritmalarının en düşük doğruluğa sahip olduğu paylaşılmıştır (Agarwal, P., ve ark. 2021).

2.10.7. İkili lojistik regresyon sınıflandırma algoritması

İkili Lojistik Regresyon (İLR), ikili değerleri almakla sınırlandırılan, bağımlı değişkenlerin modellenmesinde kullanılır (Arabameri, A., ve ark. 2019). 0 veya 1 gibi iki sonuçlu, bağımlı bir değişkenin, bir veya daha fazla bağımsız değişkenle ilişkisini modellemek için kullanılan bir hem istatistik hem de ML'de (Dewitte, o., ve ark., 2015) kullanılan bir tekniktir. Bu model, özellikle sonuç değişkeni kategorik olduğunda ve iki kategori (örneğin, yangın var/yangın yok, başarılı/başarısız, evet/hayır) arasında bir ilişkiyi incelemek istenildiğinde tercih edilir. Yöntemin kullanıldığı alanlar arasında kredi skorlaması, hastalık risk tahmini, müşteri analizi gibi alanlar bulunmaktadır. Model, sonuçları etkileyebilecek faktörler arasındaki ilişkileri ortaya çıkarmak ve tahminleme yapmak için güçlü bir araçtır.

2.10.8. Sinir ağı algoritması

Sinir ağı, biyolojik sinir sisteminden ilham alınarak tasarlanmış matematiksel bir modeldir (Tian, S., ve ark. 2022). Sınıflandırma için kullanıldığında, bir giriş katmanı, birkaç gizli katman ve bir çıkış katmanı içeren bu yöntem, verileri alır, gizli katmanlar aracılığıyla çeşitli özelliklerini öğrenir, çıkış katmanı olarak sınıflara atama yapar (Uzair, M., ve ark. 2020). Bu algoritmanın avantajları arasında, çeşitli katmanlar sayesinde öğrenme yeteneğinin çok ölçekli olmasıdır ve kolayca uyarlanabilirler (Wen, L., ve ark. 2021). Ayrıca yüksek performanslıdır. Fakat, veri kümesi hassas ve yeteri kadar kalabalık olmalıdır. Bunlara ilave olarak aşırı uyum gerçekleşebilir (Deepak, S., ve ark. 2021) ve yüksek hesaplama gücüne ihtiyaç duyarlar (Xu, H., ve ark. 2022). Literatür incelendiğinde, orman yangını dumanı algılama üzerine evrişimli sinir ağı çalışması yapıldığı görülmüştür. Renkli görüntüler üzerinde yapılan duman analiz sonuçları, önerilen modelin karmaşık manuel özellik çıkarma işlemlerini gerektirmediğini göstermiştir (Sun, X., ve ark. 2021). Farklı bir çalışmada, evrişimli sinir ağı tabanlı erken yangın algılama yöntemi üzerinde geliştirmeler yapılmıştır. Bu modelde, yöntem olarak hem sensörlerden (Adaboost-MLP) hem de video görüntülerinden (Adaboost-LBP) elde edilen veriler kullanılarak yangın tespiti gerçekleştirilmiş ve %99'un üzerinde doğruluk sağladığı görülmüştür (Saeed, F., ve ark. 2020).

2.10.9. K-En Yakın komşu algoritması

Sınıflandırma veya regresyon problemleri için kullanılan K-en yakın komşu algoritmasının farklı deneylerde oldukça verimli bir şekilde çalıştığı görülmüştür (Begum, S., ve ark. 2015). Basitçe bu algoritma, seçilen veriyi sınıflandırmak veya tahmin yapmak için, veriye en yakın K sayıda eğitilmiş örneğe bakar bunların sınıfları veya değerlerine göre tahmin yapar. Bu algoritmanın avantajları arasında, çok büyük verilerde bile hızlı, kolay uygulanması ve toleranslı çalışması yer almaktadır (Bansal, M., ve ark. 2022). Fakat bazı durumlarda, hangi komşu mesafesinin kullanılacağı ve hangi özelliğin iyi sonuç vereceği net değildir (Taunk, K., ve ark. 2019). Literatür incelendiğinde, orman yangını tahmininde K-en yakın komşu ve çok katmanlı yapay sinir ağ algoritmaları kullanılmıştır. Metodolojide 2019 ve 2020 yılları Avustralya kıtasında çıkan orman yangınları veri kümesi üzerinde çalışılmış ve performans hesaplamaları gerçekleştirilmiştir. Elde edilen sonuçlara göre, çok katmanlı yapay sinir ağı algoritması %99,96'lık en yüksek doğruluğa sahiptir ve diğer performans

hesaplamaları (F1-skör, Jaccard Skoru, R2 skoru) açısından da yapay sinir ağ algoritmasının daha başarılı olduğu paylaşılmıştır (Kumar, N., ve ark. 2020). Farklı bir çalışmada, yedi yangın kaynağı ve üç bina yapısı üzerinde deney yapılmış ve yangın kaynağının sınıflandırılması K-en yakın komşu algoritması ile belirlenmeye çalışılmıştır. Bulanık mantık destekli K-en yakın komşu algoritmasının kesinlik değerinin % 97,18 ile başarı elde ettiği sonuçlarda paylaşılmıştır (Andrew, A. M., ve ark. 2018).

Tablo 2.7. Sınıflandırma Algoritmalarının Karşılaştırması

Sınıflandırıcı	Avantajlar	Dezavantajlar
Karar Ağaçları	-Anlaşılması ve yorumlanması kolaydır. -Veriye duyarlı değildir. -Hem sınıflandırma hem de regresyon problemlerinde kullanılabilir.	-Aşırı öğrenme eğilimindedir. -Veri dengesizliğine duyarlıdır.
Rastgele Orman	-Yüksek boyutta veri kümelerinde etkilidir. -Aşırı öğrenmeye karşı dirençlidir. -Veri dengesizliğine karşı etkilidir.	-Tahmin süresi daha uzun olabilir. -Karar ağaçları gibi yorumlanması zor
Destek Vektör Makineleri	-Yüksek boyutlu veri kümelerinde etkilidir. -Aykırılıklara karşı dirençlidir. -Farklı çekirdek fonksiyonları kullanılabilir.	-Eğitim ve tahmin süreleri uzun olabilir. -Parametre ayarları gerektirebilir.
K-En Yakın Komşu	-Basit ve anlaşılması kolaydır. -Eğitim süresi yoktur. -Parametre ayarına ihtiyaç duymaz.	-Tahmin süresi yüksektir. -Çok boyutlu veri kümelerinde performans düşüktür.
Yapay Sinir Ağları	-Büyük veri kümelerinde etkili olabilir. -Doğrusal olmayan ilişkileri modelleyebilir. -Çoklu sınıflandırma problemlerinde kullanılabilir.	- Aşırı öğrenme eğilimindedir. -Eğitim süresi uzun olabilir. -Yeterli veri olmadığında performans düşük olabilir.
Gauss Naive Bayes	-Basit ve hızlıdır. -Kategorik ve sayısal veriye uygun. - Aşırı öğrenme eğiliminde değildir.	-Bağımsızlık varsayımı gerçek dünyada nadiren geçerlidir. -Eşit varyanslı veri gerektirir.
Lojistik Regresyon	-Basit ve yorumlanması kolaydır. -Binom ve çok sınıflı sınıflandırma problemlerinde kullanılabilir. -Aykırılıklara karşı dirençlidir.	-Bağımsız değişkenler arasında doğrusal ilişki varsayımı gerektirir. - Aşırı öğrenme eğilimindedir.
İkili Lojistik Regresyon	-Doğrudan olasılık tahmini yapılır. -Kolay yorumlanabilirlik.	- Aşırı öğrenme eğilimindedir. - Veri önceden hazırlama gereksinimi vardır
Gauss Süreç Sınıflandırıcısı	-Esnek ve parametrelerle oynamak kolaydır.	-Büyük veri kümelerinde yavaş olabilir.

Tablo 2.7., sıklıkla kullanılan sınıflandırma algoritmalarının avantajlarını ve dezavantajlarını karşılaştırmalı olarak sunmaktadır. Her bir algoritmanın güçlü yönleri ve karşılaşılabilecek zorluklar belirtilmiştir. KA, anlaşılması ve yorumlanması kolay olmalarıyla avantaj sağlarken, aşırı öğrenme eğilimi ve veri dengesizliğine duyarlılıkları dezavantaj olarak öne çıkar. Rastgele Orman algoritması, yüksek boyutlu verilerde etkili olması ve aşırı öğrenmeye karşı dirençli olmasıyla dikkat çeker. Fakat tahmin süresinin uzun olması ve yorumlanmasının zor olması dezavantajları arasında yer alır. Destek Vektör Makineleri, yüksek boyutlu veri kümelerinde etkililik ve aykırılıklara karşı direnç sunarken, uzun eğitim ve tahmin süreleri gibi dezavantajlara sahiptir. K-En Yakın Komşu algoritması, basitliği ve eğitim süresine ihtiyaç duymamasıyla avantajlı olup, tahmin süresinin yüksek olması ve çok boyutlu veri kümelerindeki düşük performansı dezavantajlıdır. Yapay Sinir Ağları, büyük veri kümelerinde etkili olabilir ve doğrusal olmayan ilişkileri modelleyebilir, ancak aşırı öğrenme eğilimi ve uzun eğitim süreleriyle karşılaşabilir. GNB, hızlı ve basit oluşuyla avantaj sağlarken, bağımsızlık varsayımının gerçek dünyada nadiren geçerli olması dezavantajını taşır. Lojistik Regresyon, basitlik ve aykırılıklara karşı direnç gibi avantajlara sahiptir. Fakat doğrusal ilişki varsayımı ve aşırı öğrenme eğilimi dezavantajları arasındadır. GPC, esneklik ve belirsizlik tahminleri sağlama gibi avantajlar sunarken, büyük veri kümelerinde yavaş olması ve yüksek boyutlu veri kümelerinde düşük performans göstermesi dezavantajları arasındadır. Bu karşılaştırma tablosu, farklı sınıflandırma algoritmalarının uygulanabilirliğinin, ihtiyaç duyulan sonuçlara göre değerlendirilmesi gerektiğini göstermektedir. Dolayısıyla bu tablo özeline yönelik şekilde ML ve yangınlar üzerinde çalışmalar incelenmiştir. ML, orman yangınlarını algılama sistemlerinde etkin bir rol üstlendiği literatürde çeşitli çalışmalarda görülmüştür (Arif, M., ve ark. 2021; Pham, B. T., ve ark. 2020; Anandaram, H., ve ark. 2023; Xavier, K. L. B. L., ve ark. 2022). Bu yöntemle ait algoritma, genellikle sınıflandırma modellerini kullanarak uygulanır ve yangın olasılığına ilişkin tahminler yapar (Surya, L. (2017). Böylece yanlış alarm oranları azalır ve yangınlar daha hızlı ve doğru bir şekilde tespit edilir. Dolayısıyla, yangın algılama sistemlerinin etkinliği artar ve can kayıpları ile mal zararları azalır. ML ve yangın algılama konularında yapılan araştırmalar (Toulouse, T., ve ark. 2016; Geetha, S., ve ark 2021), bu teknolojilerin daha da geliştirilmesi ve yaygınlaştırılması için önem taşır.


2.10.10. Makine öğreniminde doğrulama teknikleri

Doğrulama teknikleri, bir modelin performansını ölçmek ve ne kadar genelleşeceğini değerlendirmek amacıyla kullanılan istatistiksel yöntemlerdir. Bu teknikler, modelin eğitim sürecindeki performansını belir. Ayrıca modelin gelecekteki verilere göre nasıl genelleşeceğini tahmin etmeye çalışır. Eğitim verilerine karşı aşırı uyumu kontrol etmek ve gerçek dünya verilerindeki performansını doğru bir şekilde değerlendirmek için büyük öneme sahiptir. Doğrulama tekniklerinde genel olarak (i)K-Katlı Çapraz Doğrulama, (ii) Sınama Kümesi Doğrulama (iii) Bir Veri Noktasını Dışarda Bırakma Çapraz Doğrulama, (iv) Katmanlı K-katlı çapraz doğrulama ve (v)Bootstrapping yöntemleri yaygın bir şekilde kullanılmaktadır.

2.10.10.1. K-katlı çapraz doğrulama

Bu yöntem, performansını değerlendirmelerinde kullanılan bir doğrulama tekniği olup (Wong, T. T., 2015), ML modellerinde de sıklıkla tercih edilir (Yadav, S., ve ark. 2016). Yöntemde bir veri kümesi daha küçük parçalara bölünür ve bu parçalar kullanılarak modelin performansını değerlendirir (Nti, I. K., ve ark. 2021). Bir veri kümesi rastgele K adet eşit veya yaklaşık eşit büyüklükte parçalara ayırarak her bir parçayı sırayla test kümesi olarak kullanmayı ve kalan K-1 parçayı eğitim kümesi olarak kullanmayı içerir. Bu süreç, modelin her bir eğitim-test kombinasyonu için K kez eğitilmesini ve değerlendirilmesini gerektirir, böylece her parça bir kez test kümesi olarak işlev görür. Elde edilen performans metrikleri, modelin farklı veri segmentlerine adaptasyon yeteneğinin bir göstergesi olarak ele alınır ve sonuçlar, tüm K test kümesi üzerinden hesaplanan ortalama değerlerle rapor edilir.

Bu doğrulama tekniği, modelin genelleştirme kabiliyetinin güvenilir bir şekilde değerlendirilmesine olanak tanır ve veri kümesinin tamamını hem eğitim hem de test amaçlı kullanarak verimli bir kaynak kullanımı sağlar. Ayrıca, K-Katlı Çapraz Doğrulama, aşırı uyuma (overfitting) karşı bir koruma mekanizması olarak işlev görerek, modelin yalnızca eğitim verisine özgü özellikleri değil, genel özellikleri öğrenmesine yardımcı olur. Modelin çeşitli alt kümeler üzerindeki tutarlı performansı, seçilen algoritmanın veya modelin veri kümesinin geniş bir yelpazesi üzerindeki etkinliğine dair değerli içgörüler sunar. Dolayısıyla, K-Katlı Çapraz Doğrulama, ML projelerinde, model seçimi, hiperparametre ayarlaması ve modelin nihai genelleme performansının değerlendirilmesi süreçlerinde kritik bir role sahiptir. Aşağıdaki Şekil 2.12.'de K-katlı çapraz doğrulama'ya ait görsel paylaşılmıştır.




Şekil 2.12. Veri kümesinin eğitim ve test alt kümelerinde bölünmesi ve K-Katlı çapraz doğrulamanın gerçekleştirilmesi

Şekil 2.12, bir veri kümesinin eğitim ve test alt kümelerine nasıl bölündüğünü ve bu bölünmenin ardından K-Katlı Çapraz Doğrulama işleminin nasıl gerçekleştirildiğini ayrıntılı bir şekilde gösterir. Bu süreç, veri kümesinin modelin doğruluğunu ve genelleştirme yeteneğini değerlendirmek üzere kullanılmasını sağlar ve genellikle birkaç adımdan oluşur. İlk olarak, toplam veri kümesi, eğitim ve test olmak üzere iki ana alt kümeye ayrılır. Bu aşama, modelin eğitilmesi için kullanılacak verileri ve modelin performansının değerlendirileceği test verilerini belirlemek için kritik öneme sahiptir. Eğitim kümesi, modelin öğrenme sürecinde kullanılırken, test kümesi modelin ne kadar iyi genelleme yaptığını test etmek için kullanılır. Daha sonra, K-Katlı Çapraz Doğrulama işlemi başlar. Bu işlemde eğitim veri kümesi, K eşit veya yaklaşık eşit büyüklükteki alt kümeye (kat) bölünür. Her bir çapraz doğrulama iterasyonunda, bu K alt kümeden biri test kümesi olarak ayrılır (yani, bu iterasyonda değerlendirme için kullanılır), geriye kalan K-1 alt küme ise modelin eğitimi için kullanılır. Bu işlem, K kez tekrarlanır, böylece her alt küme tam olarak bir kez test kümesi olarak kullanılmış olur. K-Çapraz Doğrulama, modelin ne kadar genelleşeceğini kontrol etmek için kullanılır (Jiang, G., ve ark. 2017). Ayrıca, bu yöntemle elde edilen sonuçlar, tek bir test kümesi kullanıldığında elde edilen sonuçlara göre daha güvenilirdir. Ancak, K-Çapraz Doğrulama, hesaplama maliyeti daha yüksek olduğundan (Nematzadeh, Z., ve ark. 2015) büyük veri kümelerinde dikkatlice uygulanmalıdır.

2.10.10.2. Sınama Kümesi Doğrulama

Bu teknikte, veri kümesi iki alt kümeye ayrılır. Modelin performansını değerlendirmek için bu iki alt kümeden biri eğitim, diğerini ise test amacıyla kullanır (Maldonado, S., ve ark. 2021). Tekniğin kullanımı oldukça basittir ve yaygın olarak

kullanılır (May, R. J., ve ark. 2010). İlgili yöntem, öncelikle mevcut veri kümesinin, bir eğitim kümesi ve bir test kümesi olmak üzere iki ayrı alt kümeye bölünmesini gerektirir. Eğitim kümesi, genellikle veri kümesinin %70 ila %80'lik bir kısmını kaplar ve modelin öğrenme sürecinde kullanılır. Bu kapsamlı öğrenme kümesi, modelin veri üzerindeki ilişkileri ve örüntüleri öğrenmesi için gereklidir. Geri kalan kısım yani genellikle veri kümesinin %20 ila %30'luk bir bölümü, test kümesi olarak ayrılır. Bu test kümesi, eğitilen modelin, görmediği veriler üzerinde nasıl performans gösterdiğini değerlendirmek için kullanılır. Değerlendirme sonuçları modelin gerçek dünya verileri üzerindeki potansiyel başarısının bir ön gösterimidir. Aşağıdaki Şekil 2.13.'te sınaama kümesi doğrulama tekniğine ait gösterim paylaşılmıştır.




Şekil 2.13. Veri kümesinin eğitim ve test alt kümelerinde bölünmesi ve sınaama kümesi doğrulamanın gerçekleştirilmesi.

Şekil 2.13, veri kümesinin eğitim ve test alt kümelerine nasıl bölündüğünü ve bu bölünmenin ardından sınaama kümesi doğrulama işleminin nasıl gerçekleştirildiğini detaylandırır. Sınaama kümesi doğrulama süreci, modelin veri üzerindeki öğrenme kapasitesini ve yeni, görülmemiş verilere adaptasyon yeteneğini objektif bir şekilde değerlendiren kritik adımdır. Bu süreç, modelin güvenilirliğini ve uygulanabilirliğini artırırken, potansiyel iyileştirmeler için değerli içgörüler sunar.

2.10.10.3. Bir veri noktasını dışarda bırakma çapraz doğrulama

Bu teknik, K-Katlı Çapraz Doğrulama yönteminin özelleştirilmiş halidir ve doğrulama amacıyla N veri örneğinden yalnızca birinin alır, geri kalanlarını eğitim verisi olarak kullanır (Baron, G., ve ark. 2021). Veri kümesindeki her bir veri noktası için bir eğitim-test döngüsü gerçekleştirilir. Bu, modelin, veri kümesinin her bir elemanını dikkate alarak, genelleme kabiliyetini en detaylı şekilde test etmesine olanak tanır. Her döngüde, seçilen tek bir veri noktası test için ayrılırken, geriye kalan tüm veri modelin eğitimi için kullanılır. Model, bu şekilde N kez eğitilir ve her bir eğitim-test iterasyonunda, modelin performansı ölçülür. Aşağıdaki Şekil 2.14.'te veri noktasını dışarda bırakma çapraz doğrulama için örnek görsel paylaşılmıştır.




Şekil 2.14. Veri kümesinin eğitim ve test alt kümelerinde bölünmesi ve veri noktasını dışarda bırakma çapraz doğrulama.

Şekil 2.14, veri kümesinin eğitim ve test alt kümelerine nasıl bölündüğünü ve bu bölünmenin ardından gerçekleştirilen Veri Noktasını Dışarda Bırakma Çapraz Doğrulama (işleminin detaylarını sunar. Süreç, başlangıçta veri kümesinin tamamının model eğitimi için kullanılabilmesi dışında, sıradan bir eğitim-test bölünmesi prosedürüne benzer. Ancak, bu yöntemde veri kümesinin her bir elemanı sırayla ve tek tek test kümesi olarak ayrılır. Bu ayırım, veri kümesindeki N veri noktasından her biri için, kalan $N-1$ veri noktasının model eğitimi için kullanıldığı N adet eğitim-test döngüsüne yol açar. Sonuçta, her bir veri noktasının modelin doğruluğu ve genelleştirme yeteneği üzerindeki etkisini tek tek değerlendirmek için kullanılır ve ML modellerinin performans analizinde önemli bir yer tutar.

2.10.10.4. Önyüklemeli çapraz doğrulama

Bu teknik, bir veri kümesinden tekrar tekrar örneklemeler alarak istatistiksel sonuçların güvenilirliğini artırmak için kullanılır (Parady, G., ve ark. 2021). Özellikle küçük veri kümeleri veya sınırlı veriye erişim durumlarında, istatistiksel sonuçların güvenilirliğini ve doğruluğunu artırmak amacıyla kullanılan bir tekniktir. Çalışma prensibi olarak, orijinal veri kümesinden, aynı boyutta ve benzer özelliklere sahip alt veri kümeleri oluşturarak rastgele örneklemeler seçmektir (Yuan, X., ve ark. 2024). Bu yöntemde öncelikle veri kümesinden örnekleme yapılması gerekir. Ardından, bu örnekleme sürecinde kullanılacak olan küme boyutu belirlenir. Daha sonra, belirlenen küme boyutuna uygun olarak rastgele örnekleme işlemi belirlenen tekrar sayısı kadar gerçekleştirilir. Her bir tekrar için, seçilen örnekler üzerinden istatistiksel hesaplamalar yapılır. Bu hesaplamalar sonucunda elde edilen istatistiksel tahminler, sonuçların genel güvenilirliğini ve doğruluğunu artırmada kullanılır. Şekil 2.15.'te önyüklemeli çapraz doğrulama için örnek görsel paylaşılmıştır.



Şekil 2.15. Önyüklemeli çapraz doğrulama

Şekil 2.15, önyükleme ile doğrulamanın, veri kümesinde rastgele örneklemeler çekerek bu örneklemeler üzerinden istatistiksel analizler yapılmasını görsel olarak ifade etmeye yöneliktir. Önyükleme doğrulama sürecinde, ilk adımda örnekleme yapılır, daha sonra model oluşturulur. Bir sonraki aşamada, değerlendirme yapılarak sonuçlar sentezlenir. Son olarak ise önyükleme sonuçlarının dağılımı kullanılarak, tahmin edilen istatistiklerin güven aralıkları hesaplanır.

Aşağıdaki Tablo 2.8’de izahı gerçekleştirilen model doğrulama tekniklerinin kullanım amaçlarını, avantajlarını ve dezavantajlarını karşılaştırmaktadır.

Tablo 2.8. Doğrulama Tekniklerinin Karşılaştırması

Doğrulama Tekniği	Kullanım Amaçları	Avantajlar	Dezavantajlar
K-Katlı Çapraz Doğrulama	Modelin genelleşeceğini değerlendirmek	- Daha güvenilir model performansının tahmini - Veri bölümlerinden kaynaklanan varyans azaltma	- Hesaplama ve hesaplama maliyeti artabilir - Küçük veri kümelerinde doğruluk açısından zor olabilir
Sınama Kümesi Doğrulama	Modelin performansını değerlendirmek	- Hızlı ve kolay uygulanabilir - Eğitim ve doğrulama kümelerinin net ayrılması	- Veri bölümlerinden kaynaklanan varyans olabilir - Veri kümesi boyutlarına bağlı olarak yanıltıcı olabilir
Bir Veri Noktasını Dışarda Bırakma Çapraz Doğrulama	Modelin dayanıklılığını ve genelleşeceğini değerlendirmek	- Daha genelleştirilmiş bir model elde etme şansı - Küçük veri kümeleri için etkili olabilir	- Veri noktalarının dışarıda bırakılması yanıltıcı olabilir - Veri kümesi boyutlarına ve veri noktalarının dağılımına bağlı olarak sonuçlar değişebilir

Tablo 2.8.(Devamı) Doğrulama Tekniklerinin Karşılaştırması

Önyüklemeli Çapraz Doğrulama	Modelin eğitim sürecini optimize etmek ve aşırı öğrenmeyi önlemek	- Aşırı öğrenmeyi azaltabilir - Veri kümesi boyutlarına ve karmaşıklığına bağlı olarak etkili olabilir	- Ek ayarlamalar gerekebilir - Başlangıç hiperparametrelerinin seçimi önemlidir
---------------------------------	---	---	--

Tablo 2.8.'de verilen doğrulama teknikleri, belirli senaryolarda modelin geliştirilmesi, performansının değerlendirilmesi, dayanıklılığının test edilmesi, eğitim sürecinin optimizasyonu ve aşırı öğrenmenin önlenmesi gibi amaçlar için kullanılmaktadır. Bu model doğrulama tekniklerinin her birinin benzersiz avantajları ve karşılaşılan zorlukları vardır. Her teknik, belirli bir araştırma içeriğine ve modelin gereksinimlerine bağlı olarak, en uygun sonuçları elde etmek için dikkatle seçilmelidir.

2.10.11. Makine Öğreniminde İstatistiksel Analiz

İstatistiksel analiz yöntemi veri toplama, düzenleme, analiz etme, yorumlama ve sonuçları çıkarmak için sıklıkla kullanılır. Amaç, istatistiksel analiz araçlarını kullanarak her girdi değişkeninin çıktı değişkenleriyle ilişki gücünün belirleme ve özetlemektir (Tsanas, A., ve ark. 2012). İstatistiksel analiz, birçok alanda veriye dayalı karar alma sürecini desteklemek için kullanılır. Kullanılan yöntemler ve teknikler, verilerin özelliklerine ve analiz edilen problemlere bağlı olarak değişir. Bu yöntemler arasında minimum artıklık maksimum ilgililik, ki kare testi, varyans analizi (ANOVA), Kruskal Wallis testi ve zaman serisi analizi gibi çeşitli istatistiksel teknikler bulunmaktadır.

2.10.11.1. Minimum artıklık maksimum ilgililik (MAMI)

Özellik seçimi yaparken çıktı parametreleri ile yüksek ilişkisi olan ve kendi aralarında düşük ilişkiye sahip özellikleri seçmek için kullanılır (Radovic, M., ve ark. 2017). Minimum artıklık seçilen değişkenler arasındaki gereksiz ilişkiliyi filtreleme yapar ve en az boyutlu kümeyi arar. Bu durum seçilen özellikler arasındaki gereksiz yere yüksek korelasyonları filtreleyerek, en az miktarda birbirine bağımlı özellik kümesinin belirlenmesine odaklandığının göstergesidir. Maksimum ilgililikse modelin performansını artırmak için seçilen değişkenlerin hedef değişkenle olan ilişkisini maksimum düzeye çıkarmayı hedefler (Bugata, P., ve ark. 2020). Böylece, en önemli

değişkenlerin seçilmesini sağlar ve modelin karmaşıklığını azaltılır. Bu durum aşırı öğrenme sorununu önleyebilir (Afrash, M. R., ve ark. 2023). Yöntemin, hesaplama maliyetleri düşüktür, kolay ve hızlı analiz sonuçları verir (Günen, M. A. 2022).

2.10.11.2. Ki-Kare testi

Bu test, bağımsızlık testi olarak da adlandırılmaktadır ve iki kategorik değişken arasındaki ilişkiyi belirlemek için kullanılan istatistiksel yöntemdir (Fadhullah, W., ve ark. 2022). Genellikle Pearson ki-kare olarak bilinen orijinal ki-kare testi, 1900'lerin başlarında Karl Pearson tarafından yazılan makalelere dayanmaktadır (Howell, D. C. 2011). Pearson tarafından geliştirilen ki-kare uyum iyiliği testleri, bağımsızlık testleri ve homojenlik testleri modern istatistik teorisine yaptığı en önemli katkılardır. Pearson Ki-kare dağılımının önemi, istatistikçilerin bulguları yorumlamak için normal dağılıma bağlı olmayan istatistiksel yöntemleri kullanabilmesidir (Turhan, N. S. 2020). Ki-kare testi, gözlenen (G) frekanslar ile beklenen (B) frekanslar arasındaki farkın istatistik olarak anlamlı olup olmadığı temeline dayanır (Güngör, M. 2008). Ki-kare testi için aşağıdaki Formül 2.3. kullanılmaktadır

$$\chi^2 = \frac{\sum (gözlenen - beklenen)^2}{beklenen} \quad (2.3)$$

Formül 2.3'te gözlenen değerler, gerçek dünyada toplanan veya bir deney sonucunda elde edilen verilerdir. Beklenen değerler, model tahminine dayalı olarak hesaplanan değerlerdir. Ayrıca, ölçümle tanımlanan sürekli değişkenler de belli bir değerden az veya çok olarak nitelendirilerek kesikli değişkene dönüştürülebilir ve dönüştürülen bu değişkene de ki-kare testi uygulanabilir (Kılıç, S. 2016). Sonuç olarak, Ki-Kare Testi, kategorik verilerin analizinde temel bir araçtır ve iki değişken arasındaki potansiyel ilişkilerin istatistiksel olarak anlamlı olup olmadığını belirlemede etkili bir yöntemdir. Bu test, araştırmacılara, değişkenler arasındaki ilişkilerin rastlantısal olup olmadığını belirleme ve karar verme sürecinde destek sağlar.

2.10.11.3. Varyans analizi (ANOVA) testi

Bu yöntem, üç veya daha fazla grup arasında ortalamaların istatistiksel olarak anlamlı bir şekilde farklı olup olmadığını belirlemede kullanılır. H_0 grupların etkisi yoktur. H_1 ise en az iki grup arasında anlamlı bir fark olduğunu yani en az bir grubun diğerlerinden farklı olduğunu belirtir (Allassaf, M., ve ark. 2022). Varyans analizi testi, temelde iki hipotezi değerlendirir. Bunlar gruplar arasında anlamlı bir fark yok (H_0)

ve en az iki grup arasında anlamlı bir fark var (H_1) şeklindedir. Ayrıca varyans analizi testi, gruplar arasındaki değişkenliği gruplar arası varyans ve hata varyansı olarak iki bileşene ayırır. Test istatistiği, gruplar arası varyansın hata varyansına oranının bir tahmini olan F oranıdır. Elde edilen F oranı, gruplar arasındaki farklılıkların gruplar içindeki değişkenliğe göre ne kadar büyük olduğunu gösterir. Büyük bir F değeri, gruplar arasında anlamlı bir fark olduğunu düşündürebilir. Varyans analizi sonucunda elde edilen p-değeri, gruplar arasındaki farkın anlamlılığını belirler (Chen, W. H., ve ark. 2022). Eğer p-değeri belirlenen bir anlamlılık düzeyinden küçükse (genellikle 0.05 olarak kabul edilir), gruplar arasında anlamlı bir fark olduğu kabul edilir ve null hipotez reddedilir. Bu bağlamda, varyans analizi (ANOVA) testi, özellikle birden fazla grup arasında karşılaştırmalı analizler yaparken, gruplar arasındaki ortalamaların farklılıklarının istatistiksel olarak anlamlı olup olmadığını belirlemede kullanılır.

2.10.11.4. Kruskal Wallis testi

İlk defa 1952 yılında önerilen ve istatistiksel bir test olan Kruskal Wallis testi parametrik olmayan verileri inceler (Flores Tapia, C. E., ve ark. 2022). Bu test, verilerin normal dağılmadığı veya homojen varyans olmadığı koşulda kullanılır ve örneklerin aynı dağılımdan gelip gelmediğini test etmek için parametrik olmayan tek yönlü bir ANOVA yöntemidir (Cabral Júnior, J. B., ve ark. 2020; Dao, P. B., ve ark. 2024). Bu test, temelde veri kümelerinin farklı popülasyonlardan gelip gelmediğini değerlendirir ve bu bağlamda, üç veya daha fazla bağımsız grubun medyanlarını karşılaştırmak için kullanılır. Sonuç olarak, Kruskal-Wallis testi, parametrik testlerin uygulanamadığı durumlar için güçlü bir alternatif sunar ve özellikle medyan karşılaştırmalarında kullanılarak, farklı gruplar arasındaki potansiyel farklılıkların istatistiksel olarak anlamlı olup olmadığını değerlendirmede önemli bir rol oynar. Araştırmacılar, özellikle normal dağılım varsayımı karşılanmayan veya homojen varyans şartı sağlanmayan durumlarda, veri kümeleri arasındaki medyan farklılıklarını etkin bir şekilde analiz etmek için bu testi kullanır.

Aşağıdaki Tablo 2.9’da izahı gerçekleştirilen istatistiksel testlerin karşılaştırılması yapılmıştır.

Tablo 2.9. İstatistiksel testlerin karşılaştırılması.

Test Adı	Minimum Artıklık Maksimum İlgililik	Ki-Kare Testi	Varyans Analizi (ANOVA) Testi	Kruskal Wallis Testi
Temel İlke	Çoklu bağımsız değişkenler ve çoklu bağımlı değişkenler arasındaki ilişkiyi incelemek için kullanılır.	Kategorik bağımsız değişkenlerin kategorik bağımlı değişkenlerle ilişkisini incelemek için kullanılır.	Bağımsız değişkenlerin bir veya daha fazla kategorik bağımlı değişken üzerindeki etkisini incelemek için kullanılır.	Sıralı veya düzenli ölçekli bağımlı değişkenlerin tek bir kategorik bağımsız değişken üzerindeki etkisini incelemek için kullanılır.
Avantaj	- Birden fazla bağımlı değişken arasındaki ilişkiyi aynı anda değerlendirebilir. - Veri kümesindeki çoklu bağımlı değişkenler arasındaki korelasyonları hesaba katar.	- Hızlı ve kolaydır. - Gözlenen ve beklenen frekanslar arasındaki farkı değerlendirir ek kategorik değişkenlerin etkisini ölçer.	- Birden fazla grup arasındaki farklılıkları saptamak için etkili bir yöntemdir. - Grupların varyanslarını karşılaştırarak grupların homojen olup olmadığını belirleyebilir.	- Non-parametrik bir test olduğundan, veri normal dağılmadığında veya eşit varyanslı olmadığında kullanılabilir. - Gruplar arasındaki farklılıkları belirlemek için sıralı verilerle çalışabilir.
Dezavantaj	- Örneklem büyüklüğü büyüdükçe istatistiksel güç azalabilir. - Çoklu gruplar arasındaki etkileşimler karmaşık olabilir. - Veri normal dağılıma sahip olmalıdır.	- Yalnızca kategorik verilerle çalışabilir, sürekli değişkenlerle kullanılamaz. - Tek bir bağımsız değişkenin etkisini inceleyebilir, çoklu etkileşimleri değerlendiremez.	- Veriler normal dağılıma ve eşit varyansa sahip olmalıdır. - Aykırı değerler ve veri normal dağılımdan sapmalar sonuçları etkileyebilir.	- Parametrik olmayan bir test olduğundan, veri normal dağılıma sahipse ve gruplar homojen ise ANOVA'ya göre daha az hassastır. - Tekrarlanan ölçümler veya eşleştirilmiş verilerle çalışamaz.

Tablo 2.9., farklı istatistiksel testlerin temel ilkelerini, avantajlarını ve dezavantajlarını karşılaştırmaktadır. Bu testler, özellikle veri analizinde, farklı türdeki veriler üzerindeki bağımsız ve bağımlı değişkenlerin etkilerini değerlendirme amaçları için kullanılmaktadır. Bu karşılaştırma, her bir istatistiksel testin, analiz edilmek istenen

veri türüne ve araştırma sorusunun doğasına bağlı olarak hangi yöntemin seçilmesi gerektiği hakkında bir kolaylık sağlayacaktır. Araştırmacıların Tablo 2.9.'da geçen farklılıkları dikkate alarak, analizlerinde en uygun yöntemi seçmeleri gerekmektedir.

2.10.11.5. Makine öğrenimi (ML) uygulamaları

ML, verilerin bilgisayar sistemleri ile çeşitli algoritmalar kullanılarak analiz edilmesi ve otomatik öğrenme işleminin yürütülmesini sağlayan bir yapay zekâ dalıdır (Ersöz, F. ve ark., 2021). Yapay zekâ alanının alt dalı olan bu öğrenim sistemi, temelde bilgisayarın belirli bir görevi en iyi şekilde doğru olarak tahmin etmeye yönelik çalışır (Engelbrecht, A. P., 2007; Vishnukumar, H. J. ve ark., 2017). İstatistik, matematik ve bilgisayar bilimlerinden faydalanarak verilere dayalı öğrenme yeteneği kazanması amaçlanır (Qin, S. J. ve ark., 2019). Bu sistem bir dizi algoritma ve teknikleri içinde barındırır. ML için aşağıdaki adımlar uygulanır.

2.10.11.6. Veri toplama

Veri toplama sürecinde, ihtiyaç duyulan verilere yönelik kapsamlı bir çalışma, veri analitiğini daha karmaşık hale getirebilir (Smiti, A., 2020). Ancak, ML bu karmaşıklığı aşmak için güçlü bir araçtır. Dolayısıyla, ML için ilk kritik süreç veri toplama sürecidir. Bu süreçte toplanan veriler model eğitiminde kullanılır. Genellikle doğrudan kaynaklardan veya üçüncü parti veri sağlayıcılarından elde edilen veriler, sensörler veya harici otomatik kayıt cihazları yardımıyla, fiziksel ortamdan toplanan ham verilerden faydalı bilgilerin çıkarılması ve verilerin doğru şekilde analiz edilebilmesi için önemlidir (Li, W., ve ark. 2021; Dogan, A., ve ark. 2021). Ortamdan hangi tür verilere ihtiyaç duyulduğunun belirlenmesi, verilerin toplanma yöntemlerinin seçilmesi ve gerektiğinde ilgili izinlerin alınması veri toplama sürecinde yer alır.

Doğru veri toplama sayesinde, ML modelleri, büyük miktarda veriyi hızla işleyebilir ve anlamlı sonuçlar ortaya çıkarabilir (Neethirajan, S. (2020).). Bu durumda araştırmacılar veya diğer kullanıcılar karar alma süreçlerinde zamandan tasarruf eder. Sonuç olarak, veri toplama, veriye dayalı karar alma süreçlerindeki verimliliği artırarak, ML uygulamalarının temeli teşkil eder.

2.10.11.7. Özellik seçimi

Özellik seçimi veri toplama sürecinde elde edilen özelliklerin sayısını azaltmak ve modelin karmaşıklığını indirmek için kullanılır. Bu adımda gereksiz veya zayıf özellikler seçilmez. Böylece modelin genelleme yeteneğini artırır. Özellik seçimi,

belirli kriterlere göre orijinal özellik kümesinden bir alt küme elde etme işlemini gerçekleştirmede yardımcı olan, veri kümesinin ilgili özelliklerini seçen, veri işleme ölçeğinin sıkıştırılmasına imkân veren bir yöntemdir (Cai, J., ve ark., 2018). Özellik seçimi, veri kümesindeki özelliklerin istatistiksel durumlarına bakar ve geriye doğru eleme gerçekleştirilebilir. Bu yöntemde ilk olarak, tüm özellikler belirli kriterlere göre sıralanır. Ardından, en yüksek skora sahip özellikler seçilir. Özellik seçimi modelinde arama stratejilerine bağlı olarak üç yöntem işletilir. Bunlar, filtre yöntemler, sarma yöntemler ve gömülü yöntemler olarak sınıflandırılır (Mia, J., ve ark. 2016). Filtre yöntemi, verilerin genel özelliklerine dayanır ve herhangi bir öğrenme algoritması içermeyen özellikleri değerlendirir. Sarma yöntem ise önceden belirlenmiş bir öğrenme algoritmasına ihtiyaç duyar ve özellikleri seçmek için performansı değerlendirme kriteri olarak kullanır (Zhao, Z., ve ark., 2010). Gömülü yöntemler sarma yöntemlere benzer fakat sarma ve filtre yöntemlerinin hibrid halidir ve sarma yöntemlerdekinden daha güçlüdür. Bu yöntem özellikleri seçmek için kendi yerleşik yeteneklerini içeren sınıflandırma algoritmalarını kullanır (Liu, H., ve ark., 2019). Kısaca özellik seçimi, yakından ilişkili olmayan alt kümeleri ortadan kaldıran bir veri ön işlemidir (Hu, X., ve ark., 2020).

Özellik seçimi veri toplama sürecinden sonra işletilir. Dolayısıyla gereksiz veya zayıf özellikler elendiği için depolama gereksinimlerini azalır, hesaplama maliyetinin düşer, tahmine dayalı modelin yorum gücü gelişir, bilgi işlem kaynaklarının optimum seviyede kullanılır (Santiago, E., ve ark., 2018). Sonuç olarak, özellik seçimi, veri kümelerinin daha verimli kullanımını sağlayarak, ML modellerinin performansını iyileştirir ve daha hızlı, doğru kararlar alınmasına olanak tanır.

2.10.11.8. Özellik eleme

Özellik elemesi tekniği, bir veri uzayındaki giriş özelliklerinin sayısını azaltarak model performansını artırmayı, hesaplama karmaşıklığını düşürmeyi ve yorumlama seviyesini geliştirmeyi amaçlar. Bu teknik, veri uzayındaki tekrarlayan gereksiz özellikleri tanımlar ve kaldırır. Böylece ML yönteminin eğitim süresi düşer ve ML iyileştirilir (Rtayli, N. ve ark., 2020). Özellik eleme için kullanılan birçok farklı yöntem bulunmaktadır. Özyinelemeli özellik eleme (ÖÖE) ise, sınıflandırma doğruluğuna ve öğrenilen modele dayalı olarak en uygun özellik alt uzayını seçmeye çalışan bir özellik seçme yöntemidir (Jeon, H. ve ark., 2020). Sınıflandırma işlemlerinde kullanılacak en uygun özelliklerin belirlenmesi için ÖÖE metodunun

birçok farklı alan çalışmasında kullanıldığı görülmüştür (Sharma, N. V. Ve ark., 2021; Karami, G. ve ark., 2021; Gunduz, H., 2021). Özellik elemde sürecinde farklı yöntemler kullanılabilir. Bunlar geriye doğru eleme, ileriye seçim, özylenelemeli özelliğin elenmesi, özellik önem sıralaması, L1 düzenlileştirme, L2 düzenlileştirme, temel bileşenler analizi yöntemleridir. Geriye doğru eleme yöntemi, tüm özellik kümesini seçer ve bir veya daha fazla özelliği önemsizlik sıralamasına göre eler (Jović, A. ve ark. 2015; Hernández-Garduño, E., 2020). İleriye seçim yöntemi, geriye doğru eleme yöntemine zıt şekilde çalışır (Chowdhury, M. Z. I ve ark. 2020). Yöntem, elinde hiçbir veri olmadan başlar ve özellikleri önem sırasına göre birer birer ekler (Ratner, B., 2010). Katkı sağlamayan önemsizler dışarıda kalır. ÖÖE metodu, özellikleri yinelemeli olarak ortadan kaldıran bir özellik seçme yöntemidir (Sharma, N. V. ve ark., 2021) ve istenen çıktıyı tahmin etmek için özelliklerin düzenlenmesi üzerine çalışır. Özellik önem sıralaması metodu potansiyel koşulların oluşmasına katkı sağlayacak en önemli özelliklerin sıralamasını verir. Bu metot için veri kümesine toplu ayar yapılmaz, veriler kullanıldıkça özelliklerin önem sırası ortaya çıkar (Razmjoo, A. ve ark. 2017). L1 düzenlileştirme, LASSO düzenlileştirme olarak da bilinir. Yöntem özelliklere katsayılar verir ve bunları sıfıra yaklaştırır. Model basitleştirilmesinde kullanılan bu yöntem sıfıra en yakın özellikleri siler. L1 düzenlileştirme, veri algılama ve veri yakalama esnasındaki gürültüye karşı daha dayanıklıdır (Wang, F., ve ark. 2013). Ridge (veya Tikhonov) olarak da bilinen L2 düzenlileştirme metodu, büyük katsayıları daraltarak ve tüm küçük katsayıları koruyarak çoklu bağlantı ile ilgilenir (Haddadi, Y. R., ve ark. 2022). Yaygın olarak kullanılan temel bileşenler analizi, ilk birkaç bileşendeki maksimum varyansı toplayan, etkili bir boyut azaltma metodudur (Shafizadeh-Moghadam, H., 2021). Kısacası, özellik eleme, ML projelerinde veri ön işleme ve model optimizasyonunun ayrılmaz bir parçasıdır. Tablo 2.10.'da özellik eleme metotlarına ait karşılaştırmalar aşağıda verilmiştir.

Tablo 2.10. Özellik eleme metotlarının karşılaştırılması

YÖNTEM	FARKLAR	AVANTAJLAR	DEZAVANTAJLAR
Geriye Doğru Eleme	Özellikler birer birer kaldırılarak model basitleştirilir.	- Modelin daha kolay yorumlanabilir olması.	- İyi sonuçlar için gereksiz özelliklerin elenmesi zaman alabilir.
İleriye Seçim	Başlangıçta hiç özellik kullanılmaz, ardından en iyi özellikler eklenir.	- Yüksek boyutlu veri kümelerinde etkilidir.	- İyi sonuçlar için çok fazla deneme yapılabilir.
Özyinelemeli Özellik Eleme	Başlangıçta tüm özellikler kullanılır, sonra gereksiz olanlar çıkarılır.	- Otomatik ve verimlidir.	- Gereksiz özelliklerin belirlenmesi bazı durumlarda zor olabilir.
Özellik Önem Sıralaması	Özelliklerin önem dereceleri sağlanır.	- Hızlı ve etkilidir.	- Modelin türüne ve veri kümesine bağlı olarak doğrulukta farklılık gösterebilir.
L1 Düzenleştirme	LASSO regresyonu olarak da bilinir.	- Gereksiz özelliklerin katsayıları sıfıra yaklaştırılır.	- Katsayıların sıfıra yaklaştırılması nedeniyle küçük veri kümelerinde performans düşebilir.
L2 Düzenleştirme	Ridge regresyonu olarak da bilinir.	- Aşırı uyumu azaltır.	- Aşırı düzenleme, bazı durumlarda modelin esnekliğini azaltabilir.
Temel Bileşenler Analizi	Veri kümesinin boyutunu azaltırken varyansın çoğunu korur.	- Boyut azaltma ve gürültüyü azaltma.	- Yorumlana

Tablo 2.10, çeşitli özellik eleme yöntemlerini, bu yöntemlerin uygulamalardaki temel farklarını, avantajlarını ve dezavantajlarını karşılaştırmalı olarak sunmaktadır. Her bir yöntem, modelin basitleştirilmesi, yüksek boyutlu veri kümelerinde etkinlik, otomasyon ve verimlilik gibi avantajlar sunarken, bazı dezavantajlara da sahiptir. Bu dezavantajlar arasında, gereksiz özelliklerin elenmesinin zaman alması, çok sayıda deneme yapma ihtiyacı, gereksiz özelliklerin belirlenmesinin zor olması, modelin türüne ve veri kümesine bağlı olarak doğrulukta farklılık gösterebilmesi, küçük veri kümelerinde performans düşüşü ve modelin esnekliğinin azalması yer alır. Özellik eleme yöntemlerinin uygulanabilirliği ve etkinliğini değerlendirirken Tablo 9.'da yer alan bilgiler faydalı olacaktır.

Literatür taramalarında, yapay sinir ağları aracılığıyla heyelana duyarlılık çalışmalarının gerçekleştirildiği görülmüştür. Çalışmada, geriye doğru eleme ve ki-kare metodu kullanılarak, heyelanı etkileyebilecek on yedi izleme parametresi, daha

etkin bir modelleme için on bir parametreye indirgenmiştir. Ayrıca, geriye doğru eleme yönteminin %91 kesinlik oranıyla, modellemeyi daha iyi optimize ettiği ve kare-kare metoduna (%76 kesinlik oranı) göre daha etkili sonuçlar verdiği gözlemlenmiştir (Pham, B. T., ve ark. 2021). Başka bir ML çalışması ile kullanılan ileriye seçim yönteminde, insansız hava araçları ile tarım arazilerinden görüntülerin toplandığı ve tahıl verimi için L1 (LASSO) regresyonu karşılaştırmalı analizin yapıldığı görülmüştür. İleriye seçim ve LASSO regresyon yöntemlerinin verim tahmini için iyi bir yetenek gösterdiği fakat LASSO regresyonun daha fazla yetenek sergilediği bilgisi paylaşılmıştır (Shafiee, S. ve ark. 2021). Literatürde, Alzheimer hastalığı üzerine ML ile özyinelemeli özellik eliminasyonu çalışması yapıldığı görülmüştür. Manyetik rezonans görüntülerinden elde edilen gri madde, beyaz madde ve beyin omurilik sıvısı vb. gibi beyin dokularına ait bilgilerde özyinelemeli özellik eliminasyonu gerçekleştirilmiştir. Normal kontrol, hafif bilişsel bozukluk ve Alzheimer hastalığı konularının sınıflandırılmasında özyinelemeli özellik eliminasyonu ile kullanılan evrensel destek vektör makinesi sırasıyla %100, %90 ve %73,68' doğruluk elde etmiştir (Richhariya, B. ve ark. 2020). Bir çalışmada, Matlab programı için akıllı teşhis koyma sürecinde kullanılmak üzere araç geliştirildiği üzerine bilgi paylaşılmıştır. Geliştirilen Matlab aracında otuz farklı özellik önem sıralaması metodunun entegre edildiği ve karşılaştırmalı rapor çıkarıldığı aktarılmıştır (Yu, S. ve ark. 2019).


Bu çalışmada ÖÖE metodu kullanılmış olup, orijinal özelliklere bağlı şekilde, ilk olarak tahmin modelleri her bir özelliğe bir ağırlık atama yaparak eğitti. Daha sonra ağırlıkları en küçük mutlak değere sahip olan özellikler silindi özellik kümesi basitleştirildi. Bu işleyiş kalan özelliklerin sayısı yeterli sayıya yani sınıflandırma doğruluğu yeteri seviyeye ulaşana kadar devam eder (Lian, W., ve ark., 2020). Termoelektrik malzeme araştırmalarında ML yöntemleri kullanılarak yapılan çalışmaların potansiyel yaklaşımları üzerine derleyici bir çalışma yapılmıştır. Bu çalışmada termoelektrik malzemelerin özelliklerini tahmin etmek, yeni malzemelerin tasarımını hızlandırmak ve verimliliği artırmak için L1 ve L2 düzenlileştirme yöntemleri kullanılmıştır. Elde edilen sonuçlarda termoelektrik malzeme araştırmalarında yeni atılımlar ortaya çıkabileceği hakkında bilgi paylaşılmıştır (Wang, T. ve ark., 2020).



3. MATERYAL VE METOT

Günümüzde, gelişen teknoloji ile, algılama teknolojilerindeki yenilikler, dedektörler ve sensörlerin kullanımı ile yeni bir boyut kazanmaktadır. Dedektörler ve sensörler, bilimsel araştırmalardan günlük teknolojik uygulamalara kadar geniş bir alanda kullanılan temel bileşenlerdir. Geliştirilen sistemlerde, algılama teknolojilerine kazandırılan yeni yaklaşım, dedektörler ve sensörlerin kullanılmasıyla yürütülmektedir (Barmpoutis, P., ve ark. 2020,). Dedektörler ve sensörler çevresel değişiklikleri hassasiyetle algılayarak, veri toplama ve analiz işlemlerinde kritik roller üstlenirler. Fakat bir dedektör, genellikle belirli bir fiziksel veya kimyasal özelliği tespit etmek üzere optimize edilir ve sadece bu spesifik amaçla kullanılır (Gu, I. M., 2023). Sensör ise daha geneldir ve ortamdaki değişiklikleri algılamak, ölçmek veya izlemek için kullanılır (Javaid, M., ve ark. 2021). Ayrıca sensörler daha geniş bir uygulama yelpazesi içinde kullanılabilir ve çeşitli parametreleri izleyebilir.

Bu çalışmada kullanılmak üzere 50cmx70cmx20cm ebatlarında, gözlem imkânı sağlayabilmesi için önü flexiglass kapaklı bir elektrik panosu, deney amaçlı yaptırılmıştır (Şekil 1). Pano içerisinde 25Amper kontaktör, 50Amper sigorta, klemens 5kvar (Kilovolt Amper Reaktif) ve 2.5kvar kapasiteye sahip kondansatör montajı yapılmıştır. Ayrıca Şekil 17. (c)'de kırmızı renk ile gösterilmiş kontaktör ile kondansatör arasındaki kablo deney noktası olarak belirlenmiştir. Bu çalışma kapsamında, elektrik yangın koşullarının oluşmasına yönelik deneyler gerçekleştirilmiştir. Bu deneylerin temelinde, 5kvar kapasiteli bir kondansatörün kullanıldığı ve bu kondansatöre bağlı farklı kesitlerdeki kabloların performansının değerlendirilmesi yatmaktadır. Deneylerin ana amacı, kablo kesitinin üzerinden geçen akım ve oluşan ısı ve yangın koşullarının etkilerini incelemek ve anlamaktır. Farklı kesitlere sahip kablolar, elektrik akımının iletimi sırasında farklı direnç değerleri gösterirler. Her bir kablo kesiti için, akımın geçişi, yangın koşullarının oluşmasında etkili parametreler ölçülmüş ve kaydedilmiştir. Daha sonra ise 2.5kvar kondansatör ile bir önceki deneyde gerçekleştirilen kablo çeşitliliği kullanılarak deneyler tekrarlanmıştır. Böylece deneylerde çeşitlik sağlanmıştır. Aşağıdaki Şekil 3.1.'de deney amaçlı yaptırılan pano görülmektedir.



Şekil 3.1. Deney amaçlı yaptırılan elektrik panosu a) Arduino Mega b) Raspberry Pi 4 c) Deney kablosu d) Kondansatör.

Şekil 3.1, deney amaçlı yaptırılan elektrik panosunun çeşitli bileşenlerini detaylı bir şekilde göstermektedir. Bu bileşenler arasında a) Arduino Mega, b) Raspberry Pi 4, c) Deney kablosu ve d) Kondansatör bulunmaktadır, her biri deneyin farklı yönlerini incelemek üzere özenle seçilmiştir.

Özetle a) Arduino Mega, projede kullanılan mikrokontrol birimidir ve sensörlerden veri toplama, deney parametrelerini kontrol etme ve verilerin işlenmesi gibi temel görevleri üstlenir. Arduino platformu, geniş giriş/çıkış pinleri yelpazesi ve güçlü işlem kapasitesi ile karmaşık deney düzeneklerini yönetmek için idealdir. b) Raspberry Pi 4, deneyin resimlerine ait veri kaydı ve kızılötesi kamera görüntülerinin görselleştirilmesi için kullanılan kompakt bir bilgisayardır. Ayrıca, deney sırasında elde edilen verilerin gerçek zamanlı olarak izlenmesi ve depolanması için de önemli bir rol oynar. Raspberry Pi 4 esnekliği ve geniş uyumluluğu, deney düzeneğine ileri düzeyde işlevsellik ve bağlanabilirlik kazandırır. c) Deney kablosu, kondansatör ve diğer devre elemanları arasında elektrik akımının iletimini sağlar. Bu kablunun özellikleri, deneyin sonuçları üzerinde doğrudan etkili olduğundan, farklı kesitlerdeki kabloların kullanımı deneyin önemli bir parçasıdır. Kablo, yangın verilerinin elde edilmesi, akım gibi parametrelerin incelenmesinde kritik bir bileşendir. d) Kondansatör, elektrik enerjisini depolayan ve gerektiğinde bu enerjiyi devreye geri verebilen pasif bir elektronik bileşendir. Deneyde kullanılan kondansatörler, değişik kapasitelerde seçilmiş olup, deneylerde çeşitlilik sağlanmıştır.

Bir çalışmada Arduino ve Raspberry Pi ortaklaşa çalıştırıldığı görülmüştür. Bu çalışma, bir evdeki tüm ev aletlerinin web tabanlı arayüzü kullanarak kontrol edilmesini sağlayan akıllı ev otomasyon sistemi üzerinedir (Bepery, C. ve ark., 2019).

Farklı bir çalışmada ise, çevresel koşulları izleme ve düşük maliyetli kablosuz ağ bağlantısı oluşturma üzerine olduğu görülmüştür. Çalışma içerisinde Arduino mikrodenetleyiciler ile Raspberry Pi 4 mikrobilgisayarların ortaklaşa çalıştırıldığı bir sistem kurulduğu, verilerin toplandığı ve sistemin faydalarının neler olduğu (düşük maliyet, kompakt, ölçeklenebilir, özelleştirilmesi kolay ve bakımı kolay vb.) görülmüştür (Ferdoush, S. ve ark., 2014). Benzer bir şekilde farklı bir çalışmada, daha verimli tarım faaliyetleri için akıllı çiftlik uygulaması üzerine çalışma yapıldığı görülmüştür. Çalışma tavuk yetiştiriciliğinde, ortam koşullarının anlık olarak izlenmesi ve gerekli müdahalelerin uzaktan yapılması üzerinedir (Jindarat, S., ve ark. 2015). Aşağıdaki Tablo 3.1.'de Arduino ve Raspberry Pi 4 platformları ve alternatifleri hakkında bir karşılaştırma bulunmaktadır.

Tablo 3.1. Gömülü Sistem ve Geliştirme Platformlarının Özellik Karşılaştırması

Platform	Özellikler
Arduino	- Basit kullanım ve erişilebilir kullanıcı deneyimi (Funda, A., ve ark. 2018) - Geniş ve performanslı kütüphane desteği (Molina-Cantero, A. J., ve ark. 2018) - Düşük maliyet (Kanmaz, A., ve ark., 2018)
Raspberry Pi	- İşletim sistemi çalıştırır (Sainz-Raso, J., ve ark., 2019) - Güçlü işlemci (Mappuji, A., ve ark., 2016) - Fazla depolama alanı (Princy, S. E., ve ark. 2015)
NVIDIA Jetson	- Yüksek performanslı AI ve derin öğrenme yetenekleri (Mittal, S., 2019) - AI yazılım kütüphanelerini destekleme (Mittal, S., 2019) - Yüksek işlem kapasitesi (Süzen, A. A., ve ark. 2020) - Geniş donanım desteği (Shin, D. J., ve ark., 2022)
STM32	- Yüksek performanslı (Herasymenko, P., 2021) - Düşük güç tüketimi (Zanghieri, M., ve ark., 2023)
ESP8266/ESP32	- Hafif ve düşük maliyetli, WiFi yetenekleri ile nesnelerin interneti (IoT) odaklı çalışma (Hernandez, S. M., ve ark., 2020)
BeagleBone	- İşletim sistemi çalıştırır (Zainudin, W. M. L. W., ve ark. 2020) - Güçlü işlemci (Dharshini, S., ve ark. 2022)

Tablo 3.1, çeşitli gömülü sistem ve geliştirme platformlarının kritik özelliklerini karşılaştırmalı olarak sunmaktadır. Arduino, basit kullanımı, erişilebilir kullanıcı deneyimi, geniş kütüphane desteği ve düşük maliyeti ile öne çıkmaktadır, bu da onu özellikle hobi projeleri ve eğitim amaçlı uygulamalar için popüler bir seçenek haline getirir. Raspberry Pi ise işletim sistemi çalıştırabilme özelliği, güçlü işlemcisi ve fazla depolama alanı sayesinde daha karmaşık projelerde ve eğitim alanında tercih edilmektedir. NVIDIA Jetson, yüksek performanslı yapay zekâ ve derin öğrenme yetenekleri, yazılım kütüphaneleri desteği, yüksek işlem kapasitesi ve geniş donanım

desteđi ile yapay zekâ odaklı uygulamalarda öncü bir platformdur. STM32, yüksek performansı ve düşük güç tüketimi ile endüstriyel uygulamalar ve enerji verimli projeler için idealdir. ESP8266/ESP32, hafif yapısı, düşük maliyeti ve Wi-Fi yetenekleri ile IoT projelerinde sıkça tercih edilmektedir. BeagleBone, işletim sistemi çalıştırabilme kapasitesi ve güçlü işlemcisi ile hem eğitim hem de profesyonel projeler için güçlü bir seçenek sunar. Bu platformların her biri, belirli gereksinimleri ve kullanım senaryolarını karşılamak üzere özelleştirilmiş özelliklerle donatılmıştır, böylelikle araştırmacılar, projelerinin ihtiyaçlarına en uygun platformu seçebilirler.

3.1. Arduino

Arduino, donanım ve açık kaynak kodlu yazılım şirkettir (McRoberts, M. 2013). Bu şirket, kullanıcıların basitleştirilmiş C veya C++ programlama dili ile kodlama yapmalarına imkân tanıyan mikrodeneleyici kartları üretir ve kullanıcılar bu kartlarla prototip platformlar tasarlar (Badamasi, Y. A., 2014). Basitleştirilmiş mikrodeneleyici kartlara farklı modüller takılarak prototip platform geliştirilebilir (Kondaveeti, H. K., ve ark. 2021). Aşağıdaki Şekil 3.2.'de prototip platform geliştirme süreci görselleştirilmiştir.



Şekil 3.2. Arduino ile problemin tanımlanması ve prototip geliştirme süreci (Kondaveeti, H. K., ve ark. 2021).

Şekil 3.2.'de görüldüğü gibi Arduino projeleri birkaç temel adımdan oluşur. Bu adımlar, problemin belirlenmesi, kavramsallaştırma, ve prototip oluşturma şeklindedir ve projenin başarısını sağlamak için dikkatlice irdelenmesi gerekir. Arduino modülleri çip kullanır ve genellikle bunlar ATmega328, ATmega1280 ve ATmega2560 çipleridir (Boloor, A. J. (2015).). Bu çipleri kullanan mikrodeneleyicilere şirket farklı isimler vermiş ve bunlar Uno, Nano, Mega, Leonardo ve Due olarak adlandırılmıştır.


Arduino mikrodeneleyici çeşitleri (Purdum, J., & Purdum, J. 2015) Tablo 3.2.'de verilmiştir.

Tablo 3.2. Arduino mikrodnetleyicileri modellerinin teknik özellik karşılaştırması

Model Adı	Görsel	Açıklama
Arduino Uno		1. • Mikrodnetleyici: ATmega328 • Flash Hafıza: 32 kB • SRAM: 2 kB • EEPROM: 1 kB • Saat Hızı: 16 MHz
Arduino Nano		• Mikrodnetleyici: NanoV3ATmega328 • Flash Bellek: ATmega328 için 32 kB, ATmega168 için 16 kB • SRAM: ATmega328 için 2 kB, ATmega168 için 1 kB • EEPROM: ATmega328 için 1 kB, ATmega168 için 512 byte 2. Saat hızı: 16 MHz
Arduino Mega		• Mikrodnetleyici: ATmega2560 • Flash Bellek: 256 kB • SRAM: 8 kB • EEPROM: 4 kB • Saat hızı: 16 MHz
Arduino Leonardo		• Mikrodnetleyici: ATmega32u4 • Flash Bellek: 32 kB • SRAM: 2.5 kB • EEPROM: 1 kB • Saat hızı: 16 MHz
Arduino Due		• Mikrodnetleyici : Atmel SAM3X8E ARM Cortex-M3 • Flash Bellek: 512 kB hepsi kullanıcı uygulamaları için kullanılabilir • SRAM: 96 kB • EEPROM: - • Saat Hızı: 84 MHz

Tablo 3.2. Arduino mikrodnetleyici platformunun çeşitli modellerinin teknik özelliklerini karşılaştırmaktadır. Bu karşılaştırma, her bir modelin mikrodnetleyici tipi, flash hafıza kapasitesi, SRAM (Statik Rastgele Erişim Belleği), EEPROM (Elektrikle Silinebilir Programlanabilir Okunur Bellek) ve saat hızı gibi temel teknik özelliklerini içermektedir. Bu teknik özellikler, her bir Arduino modelinin belirli uygulama gereksinimlerine göre seçilmesine olanak tanır, böylece araştırmacılar projelerinin ihtiyaçlarına en uygun donanımı seçer. Yapılan araştırmalarda, genelde

yukarıdaki Tablo 11’de yer alan Arduino mikrodnetleyicilerden hariç Micro, GİGA, Zero, MKR, Tre, Lilypad, Mini çeşitleri olduğu görülmüştür (web adresi 1, 24.02.2024; Hurtuk, J., ve ark. , 2017). Arduino mikrodnetleyiciler modüler yapı ve açık kaynak erişimi sağlaması, model çeşitliliği ve ekonomik fiyat yelpazesi, geniş kullanım alanı ve kolay entegrasyon sayesinde büyük avantajlara sahiptir (Guzmán-Fernández, M., ve ark. 2021; Gao, W., ve ark. 2021; Martin, S., ve ark. 2021). Bu çalışmada Arduino Mega 2560 modeli verileri toplama amaçlı kullanılmıştır. Aşağıda Şekil 3.3.’de Arduino Mega ile verilerin toplanmasına yönelik şema yer almaktadır.



Şekil 3.3. Arduino Mega yangın algılama sistemi sinyal işleme şeması.

Şekil 3.3., Arduino Mega tabanlı bir yangın verilerini toplama, voltaj ve akım değerlerini ölçme sisteminin sinyal işleme şemasını göstermektedir. Bu şema, yangın algılama sensörlerinden alınan sinyallerin nasıl toplandığını ve IoT ile haberleşmenin nasıl sağlandığını göstermektedir. Öncelikle, gaz, sıcaklık ve ortam hava kalite ölçüm sensörleri çevreden sinyaller toplar ve bu sinyaller Arduino Mega mikrodnetleyicisine iletilir. Arduino Mega, gelen sinyalleri çıkış modülüne yönlendirir. Tüm veriler thingspeak.com bulut sistemine anlık olarak her 2 saniyede bir döngü halinde iletilir. Bu süreç, Arduino Mega mikrodnetleyicinin temel işlevselliğini ve sinyal akışını özetler. Bu şema, yangın güvenliği sistemlerinin tasarımı ve uygulamasında kritik bir rol oynayan sinyal işleme mekanizmasının anlaşılmasına yardımcı olabilir. Ayrıca Şekil 19.’da şematik olarak verilen bu sistem

yangın algılama sistemi, elektrik panolarının durumlarını kontrol etmek, bileşenlerinin kullanılabilirliğini artırmak, hata süresini azaltmak ve insan gücünü daha verimli kullanmak amacıyla da değiştirilebilir. IoT çözümlü yangın algılama sistemi mevcut bir sistemin işleyişini kontrol etmede ve elektriksel sistem hatalarının haber verilmesi aşamasında da etkin bir rol üstlenebilir. Bir elektrik panosunun yangın sonrası yenileme süreci, panonun içerisinde yer alan çeşitli ekipmanların üretim yılı, farklı üreticilere ait olması ve çevresel koşullardan dolayı heterojen yaşlanma gibi faktörlerden ötürü önemli zorluklar içermektedir. Bu zorluklar, ardışık ekipman nesillerinin değişkenliği, pano içi elemanların üretici farklılıklarından kaynaklanan uyumsuzlukları ve çeşitli çevresel faktörlerin ekipmanların aşınma ve yıpranma durumlarını farklılaştırması gibi problemleri içerir. Öte yandan, elektrik panosu için tasarlanan yangın algılama sisteminin temel özellikleri küçük fiziksel boyut, düşük maliyet, sınırlı işlem gücü, düşük pil kapasitesi ve kısa menzilli kablosuz iletişim gibi kısıtlamalarla çalışacak şekilde olmasını gerektirmektedir. Bu özellikler, sistemin yangın algılama ve uyarı konusunda etkin olmasını sağlarken aynı zamanda maliyet ve fiziksel yerleşim açısından da verimli bir çözüm sunacaktır. Ancak, yenileme sürecinde karşılaşılan zorluklar, bu tür sistemlerin entegrasyonunu ve etkin çalışmasını engelleyebilecek potansiyel faktörler arasında yer almaktadır. Bu nedenle, yangın algılama sistem tasarımı ve entegrasyonu mevcut pano için düzenlenmemiştir. Fakat küçük eklemeler ile bu düzenleme yapılabilir.

3.2. Sensörler

3.2.1. MQ-4 Gaz ölçüm modülü

Mekanlarda CH₄ ve türevi gaz kaçağı tespiti için uygundur. Bu sensör hızlı çalışmasının yanı sıra stabil sonuçlar verir. Fakat dumana karşı hassasiyeti düşüktür. Ölçüm aralığı 300 ppm'den 10000 ppm'e kadar geniş bir yelpazeyi kapsar.

3.2.2. MQ-135 Hava Kalitesi Algılama

Mekanlarda NH₃ (amonyak), NO_x (azot oksit türevleri), alkol, benzen C₆H₆, duman, CO₂ CO vb. algılama için uygundur. Yüksek hassasiyetlidir, hızlı cevap verir ve stabil sonuçlar üretir. Ölçüm aralığı 10ppm-1000ppm'dir. Doğru ölçüm için sıcaklık ve nem etkisi göz önünde bulundurulması gerekir.


3.2.3. DHT22 Nem ve Sıcaklık Algılama

Bu sensör, yüksek doğrulukla hem sıcaklık hem de nem ölçümü yapabilen bir sensördür ve yaygın olarak kullanılır. Bu sensör, -40 °C ile +80 °C arasındaki sıcaklıkları ± 0.5 °C doğrulukla gerçekleştirebilir. DHT22'nin dayanıklı yapısı, uzun ömürlü kullanımı ve düşük güç tüketimi gibi özellikleri onu araştırma projeleri için ideal bir tercih haline getirir.

3.2.4. PZEM-004T-100A Güç Volt Akım Test Modülü

Bu modül, elektriksel yüklerin gerilim, akım, güç ve enerji tüketimi gibi parametrelerini ölçmek için üretilir. Bu modül, 0-100A aralığındaki akım değerlerini ve 80-260V AC voltaj aralığını ölçebilir. Modül, gerçek zamanlı elektrik verilerini ölçerek, enerji verimliliği ve maliyet tasarrufu stratejilerinin geliştirilmesine yardımcı olur.

Bu çalışmada, çeşitli sensörlerden elde edilen verilerin Arduino Mega mikrodenetleyici üzerinden işlenmesi ve analiz edilmesi süreci incelenmiştir. Sensörler, ölçüm sonuçlarını mikrodenetleyiciye aktarmış, ardından bu veriler işlenerek analiz için hazır hale getirilmiştir. İletişim ve veri transferi için Com4 iletişim portu kullanılmıştır. Ayrıca, Esp 8266 Wifi modülü aracılığıyla IoT üzerinden veri iletişimi sağlanarak, elde edilen sonuçların uzaktan erişime açık bir şekilde paylaşılması ve izlenmesi mümkün kılınmıştır. Com4 portu üzerinden gerçekleştirilen iletişim ekranı, Şekil 3.4.'te gösterilmiştir.




(a) (b) (c)

Şekil 3.4. Arduino mikro kontrol sistemi (a) Com4 portu iletişim ekranı (b) veri akışı (c) derleyici program ile geliştirilen kodlama ekranı.

Şekil 3.4.'te yer alan görseller, iletişim protokolünün nasıl kurulduğunu ve veri akışının nasıl gerçekleştiğini açıkça ortaya koymaktadır. Şekil 3.4. (a) Com4 portu iletişim ekranı, (b) veri akışı ekranının ve (c) derleyici program ile geliştirilen kodlama

ekranı göstermektedir. Sensörlerden alınan verilerin doğru ve etkin bir şekilde işlenmesi ve iletilmesi, bu tür sistemlerin performansı ve güvenilirliği açısından kritik öneme sahiptir. Bu çalışma, mikrodenetleyiciler ve kablosuz iletişim modülleri kullanılarak gerçekleştirilen veri toplama ve iletim süreçleri aşağıdaki Şekil 3.5.'te akış diyagramı olarak paylaşılmıştır.




Şekil 3.5. Arduino kod bloğu algoritma akış diyagramı.

Şekil 3.5 'te sunulan Arduino kod bloğu algoritma akış diyagramı, verilerin Arduino Mega ile için geliştirilen programının nasıl işlediğini görsel olarak temsil eder. Bu akış diyagramı, genellikle programın başlangıcı, karar alma noktaları, işlem adımları ve programın sonu gibi temel bileşenleri içerir. Diyagramın başında "Başla" simgesi kod bloğunun ilk başlangıç notasıdır. Sensörlerden doğru verilerin toplanabilmesi için 15 saniyelik ısınma süresi verilir. Sonraki aşamada ağ bağlantısı protokolü sağlanır. Thingspeak.com üzerinden özel olarak açılan anahtar protokoldeki ile eşleşme durumu

kontrol edilir. Bağlantıda ve anahtarda hata yoksa sıcaklık ve nem değerleri ölçülür. Daha sonra CO, CO₂ ve hava kalite sensöründen veriler alınır. Daha sonra hidrokarbon ölçümü, duman ölçümü yapılır. En sonda ise toplanan veriler thingspeak.com üzerindeki özel kanala aktarılır. Bu süreç toplam 2 saniye sürer ve tekrar sıcaklık ve nem ölçüm sensöründe veri alınma sürecine geçilir. Kullanıcı tarafından bu ölçüm verilerini aktarılması Arduino Mega'nın kapatılmasına kadar sürer. Ayrıca thingspeak.com veri aktarma sınırına ulaşıncaya kadar akış sürdürülebilir.

3.3. Raspberry Pi

Raspberry Pi, yüksek erişilebilirlik ve esneklik özellikleriyle dikkat çeken, kompakt boyutlu ve ekonomik bir bilgisayar kartıdır. Küçük boyutlu ve düşük maliyetli bir bilgisayar kartı olarak geliştirilmiş ve ilk olarak 2012 yılında satışı başlamıştır (Johnston, S. J., ve ark. 2017). Arduino mikrodenetleyici özelliklerine benzer olarak, küçük boyut ve geniş uygulama alanına sahiptir. Arduino mikrodenetleyici platformlarıyla benzerlik gösterse de Raspberry Pi'nin bütünleşmiş internet iletişim modülü ve daha yüksek RAM kapasitesi gibi önemli farklılıkları bulunmaktadır, bu da onu daha geniş bir uygulama spektrumunda kullanılabilir kılar (Vujović, V., 2014). Görüntü yakalama ve işleme gibi işlemci yoğun görevler için mükemmel bir kapasite sunar ve Raspbian adı verilen, özel olarak optimize edilmiş Linux tabanlı bir işletim sistemini çalıştırır (Vujović, V., 2014; Mudaliar, M. D., ve ark., 2020; Jolles, J. W., 2021). Raspberry Pi, Python, C/C++, Java ve JavaScript dahil olmak üzere çeşitli programlama dillerini destekler, bu da geliştiricilere geniş bir esneklik ve uygulama geliştirme özgürlüğü sunar (Wallace, S., ve ark., 2021). Bu özellikler, Raspberry Pi'yi araştırmacılar için projelerinde geniş bir yelpazede ideal bir seçim yapmasına imkân sağlar. Ayrıca, açık kaynaklı yazılım ve donanım topluluğundan geniş destek alması, kullanıcıların kaynaklara kolay erişimini ve projeler üzerinde ortak çalışmayı teşvik eder, böylece yenilikçi uygulamaların ve çözümlerin geliştirilmesine katkıda bulunur. Raspberry Pi için birçok farklı model çeşidi bulunmaktadır. Bunlar arasında en genel kullanılan ürünler Raspberry Pi 5, Raspberry Pi 4, Raspberry Pi 3, Raspberry Pi Pico'dur (McManus, S., ve ark. 2021). Aşağıda Şekil 3.6.'da Raspberry Pi ile verilerin ve görüntülerin toplanmasına yönelik şema yer almaktadır.



Şekil 3.6. Raspberry Pi 4 yangın algılama sistemi sinyal işleme şeması.


Şekil 3.6., Raspberry Pi 4 tabanlı, yangın verilerinin algılanmasına yönelik bir sisteminin sinyal ve görüntü işleme şemasını detaylandırmaktadır. Bu şema, sıcaklık ve nem sensöründen alınan verilerin nasıl işlendiğini, kızılötesi kamera ile görüntülerin nasıl elde edildiğini görsel olarak sunar. Raspberry Pi 4, bu sistemde merkezi bir işlem birimi olarak kullanılmakta gelen verileri ve görüntüleri toplamadaki, işlemdeki görevlerini göstermektedir. Verilerini ve görüntüleri hem kaydeder, hem de bu bilgileri ağ üzerinden uzaktan erişim için bulut tabanlı hizmetlere (thingspeak.com, Google drive) gönderir. Ayrıca Raspberry Pi 4 güçlü işlem kapasitesi ve geniş bağlantı seçenekleri ile karmaşık görevleri daha kolay yerine getirir.

3.3.1. IR Kamera

MLX90640 IR Termal Görüntüleme Kamerası, Melexis tarafından geliştirilmiş, orta çözünürlüklü bir kızılötesi (IR) termal kamera sensörüdür. Bu sensör, 32x24 piksel çözünürlüğe sahip bir termal görüntüleme matrisinden oluşur ve bir nesnenin yüzey sıcaklığını -40°C ile +300°C arasında bir sıcaklık aralığında hassas bir şekilde ölçebilir. MLX90640, geniş bir görüş açısına sahip olup, kullanıcıların geniş alanları kolayca taramasına ve termal varyasyonları net bir şekilde görmesine olanak tanır. Küçük boyutu ve I2C haberleşme protokol arayüzü üzerinden kolay entegrasyon imkânı sunması nedeniyle, MLX90640 çeşitli uygulamalar için idealdir. Bu uygulamalar arasında enerji verimliliği denetimleri, elektrik panolarında sıcak nokta

tespiti, ısıtma, havalandırma ve iklimlendirme sistemlerinin izlenmesi, vücut sıcaklığı ölçümü ve çevresel izleme bulunmaktadır. Sensör, aynı zamanda taşınabilir ve sabit termal görüntüleme çözümleri için de tercih edilen bir bileşendir. MLX90640'ın diğer özelliklerinden biri ise yüksek hassasiyetli termal görüntüleme sağlamasıdır. Bu, kullanıcılara, küçük sıcaklık farklılıklarını bile tespit edebilme yeteneği verir, bu da özellikle erken aşama arıza tespiti ve enerji kaybı analizleri için çok değerlidir. Ayrıca, bu sensör, düşük güç tüketimiyle de öne çıkar ve pil ile çalışan uygulamalar için uygundur. Son olarak bu kameranın ölçüm aralığı $-40^{\circ}\text{C} \sim 300^{\circ}\text{C}$ derece arasındadır ve ölçüm doğruluğu $\pm 1^{\circ}\text{C}$ 'dir.

Raspberry Pi 4 ilk çalıştırılması sürecinde, sistem, DHT22 sıcaklık ve nem sensörünün uygun çalışma sıcaklığına ulaşmasını sağlamak için 15 saniye bekler. Bu ön ısınma süresi, sensörün doğru ve tutarlı ölçümler yapabilmesi için kritik öneme sahiptir. Aynı zamanda, MLX90640 kızılötesi termal kamera da bu süre zarfında aktif hale getirilir, bu da sistemin termal görüntüleme kabiliyetlerini devreye sokar. Bu başlangıç aşamasından sonra, sistem ethernet kartı aracılığıyla kablolu internet bağlantısını kurma protokolünü tetikler. Bağlantının başarıyla kurulmasının ardından, sistem, thingspeak.com üzerinde önceden oluşturulmuş olan ve private channel ID 1685195 ile tanımlanmış bir bulut kanalıyla iletişime geçmek üzere programlanmıştır. İletişim kurulduktan sonra, DHT22 sensörü tarafından sıcaklık ve nem değerleri ile MLX90640 kızılötesi termal kameranın ölçtüğü deney kablosu üzerindeki odak sıcaklık değerleri her 4 saniyede bir kaydedilmeye başlanır. Bu ölçümler, gerçek zamanlı veri analizi ve izleme için thingspeak.com bulut sistemine aktarılır. Raspberry Pi 4, Arduino Mega'ya kıyasla benzersiz avantajı, MLX90640 kızılötesi termal kameranın elde ettiği görüntüleri hem yerel hafızada saklayabilmesi hem de Google Drive ile bütünleşik çalışarak bu görüntüleri belirli aralıklarla otomatik olarak Google Drive hesabına yedeklemesidir. Bu özellik, veri kaybı riskini minimize ederken, aynı zamanda uzaktan erişim ve analiz imkânı sunar. Güvenilirlik ve erişilebilirlik açısından Raspberry Pi 4 görüntüleri bir ispat niteliğindedir. Aşağıdaki Şekil 3.7.'de deney kablosu olarak seçilen bölgede elde edilen kızıl ötesi görüntülerin örnekleme bulunmaktadır.



Şekil 3.7. Kontaktör ile kondansatör arasındaki kablonun kızılötesi termal kamera görüntü örnekleri.

Şekil 3.7.'deki örnek görüntüler, 2.5 kvar kondansatör panoda takılıyken 2mm kalınlıktaki beyaz çok telli (TTR) kablo ile gerçekleştirilen deney esnasında MLX90640 kızılötesi termal kameranın çektiği görüntülerdir. Deney başlangıç aşamasında kabloda ölçülen sıcaklık değeri 24.2° C olup, deney tamamlanma aşamasında ise kabloda ölçülen sıcaklık değeri 28.6° C derecedir. Görüntülerde, deney sonunda kablonun kontaktör bağlantı noktasında kızılötesi termal sıcaklığın daha belirginleştiği tespit edilmiştir. Örnekler üzerine kodlama ile tarih ve saat verileri otomatik eklenmiştir. Bu kodlama tüm deney görüntülerinde kullanılmıştır. Ayrıca tarih ve saat benzersiz kayıt ismi oluşturduğu için kullanılmıştır. Aşağıda Şekil 3.8.'de MLX90640 kızılötesi termal kameradan elde edilen görüntülerin Python programlama dili kodlama ekranı bulunmaktadır.

```
seed_python_ircamera.py X
214 self.ellipseItem.setPen(QColor(Qt.white))
215 self.horLineItem.setPen(QColor(Qt.white))
216 self.verLineItem.setPen(QColor(Qt.white))
217 self.ellipseItem.setZValue(self.baseZValue + 1)
218 self.horLineItem.setZValue(self.baseZValue + 1)
219 self.verLineItem.setZValue(self.baseZValue + 1)
220 self.scene.addItem(self.ellipseItem)
221 self.scene.addItem(self.horLineItem)
222 self.scene.addItem(self.verLineItem)
223 # camera item
224 self.cameraBuffer = QPixmap(self.width, self.height + self.textLineHeight)
225 self.cameraItem = QGraphicsPixmapItem()
226 if self.useBlur:
227     self.gusBlurEffect = QGraphicsBlurEffect()
228     self.gusBlurEffect.setBlurRadius(self.blurRadius)
229     self.cameraItem.setGraphicsEffect(self.gusBlurEffect)
230 self.cameraItem.setPos(0, 0)
231 self.cameraItem.setZValue(self.baseZValue)
```

```
Shell
Python 3.9.2 (/usr/bin/python3)
>>>
```

Şekil 3.8. Thonny Python derleyici IR kamera kodlama ekranı

Şekil 3.8, Thonny Python derleyici MLX90640 kızılötesi termal kamera kodlama ekranı kodlamalarının bir kısmını göstermektedir. Raspbian işletim sistemi üzerinde Thonny Python entegre geliştirme ortamı (EGO) üzerinde çalıştırılmaktadır. Thonny, özellikle Python başlangıç seviyesi kullanıcıları için tasarlanmış bir EGO'dır. Aşağıda Tablo 3.3.'te Arduino Mega ve Raspberry Pi 4 karşılaştırılmıştır.

Tablo 3.3. Arduino Mega ve Raspberry Pi 4 karşılaştırma

	Avantaj	Dezavantaj
Arduino Mega	1. Gerçek zamanlı uygulamalar için idealdir. Anlık tepki gerektiren gömülü sistem projelerinde tercih edilir. 2. Düşük güç tüketimi: Pil ile çalışan projelerde uzun pil ömrü sağlar. 3. Fiziksel giriş/çıkış pinleri üzerinde yüksek kontrol sağlar. Sensörler, motorlar, LED'ler gibi bileşenlerle doğrudan etkileşim kurmak için uygundur. 4. Geniş bir topluluk ve kaynak kitaplığı vardır, bu da projelerinizde kolayca bulunabilecek kaynaklara erişim sağlar.	1. Sınırlı işlemci gücü ve bellek kapasitesi: Karmaşık işlemler için yetersiz olabilir. 2. Grafik kullanıcı arayüzleri oluşturmak zordur veya sınırlıdır. 3. Ağ bağlantısı veya internet erişimi için ek bileşenler gerekebilir. 4. Genellikle bir bilgisayar veya Raspberry Pi gibi bir bilgisayar aracılığıyla programlanır ve kontrol edilir.
Raspberry Pi 4	1. Yüksek işlem gücü ve bellek kapasitesi: Raspberry Pi 4, genel amaçlı bilgisayar işlemleri için oldukça güçlüdür. 2. HDMI çıkışı ve grafik işleme yetenekleri, medya oynatma veya görsel uygulamalar için idealdir. 3. Genişletilebilirlik: USB, Ethernet ve Wi-Fi gibi bir dizi bağlantı noktası ile birçok cihaza kolayca bağlanabilir. 4. Debian tabanlı Raspbian gibi kullanıcı dostu işletim sistemleri ve geniş bir yazılım ekosistemi mevcuttur.	1. Daha yüksek güç tüketimi: Pil ile çalışan projeler için uygun değildir. 2. Gerçek zamanlı uygulamalar için Arduino kadar uygun değildir. 3. Fiziksel giriş/çıkış pinleri Arduino Mega'ya kıyasla daha sınırlıdır. 4. Güvenilirlik: Yazılım tabanlı bir cihaz olduğu için kesintiler veya donmalar yaşanabilir.

Tablo 3.3, Arduino Mega ve Raspberry Pi 4 arasında detaylı bir karşılaştırma yapmaktadır. Her iki cihaz da kendine özgü avantajları ve dezavantajları ile öne çıkmaktadır. Arduino Mega, gerçek zamanlı uygulamalar ve düşük güç tüketimi gerektiren gömülü sistem projeleri için idealdir. Fiziksel giriş/çıkış pinleri üzerinde sağladığı yüksek kontrol, sensörler ve motorlar gibi bileşenlerle doğrudan etkileşim kurmayı kolaylaştırır. Ancak, sınırlı işlemci gücü ve belleği nedeniyle karmaşık işlemler için yetersiz kalabilir ve grafik kullanıcı arayüzleri oluşturmakta güçlük çeker. Bu çalışmada da ilk başta kamera görüntülerinin elde edilmesinde kullanılmasına

rağmen yeterli verim elde edilememiştir. Arduino Mega üzerinden elde edilen görüntüler üçüncü görüntüden sonra hafıza (RAM) yetersizliği sebebiyle cihazın çalışmasını durdurmuştur. Arduino Mega kapatılıp açıldıktan sonra tekrar çalışmış fakat her seferinde cihazda cevap verememe durumu tekrar oluşmuştur. Dolayısıyla görüntülerin toplanmasında Raspberry Pi 4 tercih edilmiştir.

Diğer taraftan, Raspberry Pi , yüksek işlem gücü ve bellek kapasitesi ile genel amaçlı bilgisayar işlemlerinde etkileyici performans sunar. HDMI çıkışı ve gelişmiş grafik işleme yetenekleri sayesinde medya oynatma ve görsel uygulamalar için uygundur. Ayrıca, USB, Ethernet ve Wi-Fi gibi genişletilebilir bağlantı seçenekleri ile çeşitli cihazlara kolayca bağlanabilir. Ancak, daha yüksek güç tüketimi ve gerçek zamanlı uygulamalar için Arduino'ya göre daha az uygun olması gibi dezavantajları vardır.

Bu karşılaştırmadan çıkan sonuç, her iki platformun da belirli senaryolar için avantajlar sağladığı ve seçimin, projenin gereksinimlerine bağlı olarak yapılması gerektiğidir. Arduino Mega, düşük güç tüketimi ve yüksek kontrol gerektiren durumlar için, Raspberry Pi ise güçlü işlem kapasitesi ve çoklu bağlantı seçenekleri gerektiren uygulamalar için daha uygundur.

3.4. Deney Kablosu


Elektrik panosunda deney amaçlı kullanılan kablo, deneylerde çeşitlilik sağlanması amaçlıdır. Yalıtkan bir dış kaplamaya sahip olan ve iç kısımlarında iletken malzemeler bulunan kablolar, elektrik akımını güvenli ve kontrollü bir şekilde taşımak için tasarlanmıştır. Bu kablolar, elektrikle ilgili deneyler yapılmadan önce farklılaştırılmış ve güvenli şekilde deneyler yapılmıştır. Böylece, deney ortamında, elektriksel deneylerin güvenli bir şekilde yürütülmesi için optimal koşullar sağlanmıştır. Bu kabloların kullanımı, çalışmadaki veri toplama süreçlerini destekler. Aşağıdaki Şekil 3.9.'da görseli paylaşılan siyah kablolar pano tasarlandığında ilk takılı olarak gelen kablolardır. Deneylerde normal kablo olarak adlandırılmıştır. PVC izolasyon malzemesine sahip TTR kablodur. Kesiti 4,8mm'dir.



Şekil 3.9. Panoda kullanılan orijinal siyah renkli kablo.

Şekil 3.9, deney amaçlı kullanılan elektrik panosundaki orijinal siyah renkli kabloyu göstermektedir. İçerisindeki iletken malzeme bakır metalindendir. Bu kablo, elektrik panosu uygulamalarında kritik bir rol oynar. Çünkü tüm normal koşul verileri bu kablo performansına göre değerlendirilmiştir.

5kvar kondansatör, deney panosuna Şekil 3.1. (c) görselindeki gibi takıldığında 8 farklı deney gerçekleştirilmiştir. Gerçekleştirilen bu deneylerde kullanılan kablolar ise Şekil 3.10.'da gösterilmiştir. Mavi renkli dışı PVC kaplı TTR kabloların her birinin kesitleri 3mm boyutundadır. Beyaz renkli kablolar ise dışı PVC kaplı TTR kabloların kesitleri ise 2 mm'dir. Beyaz kablolar 3 kat, 2 kat ve tek kat kullanılarak deneye tabi tutulmuştur. Şekil 3.9.'da gösterilen kablolardan biri ve Şekil 3.10.'da gösterilen kabloların tümü 5kvar kondansatör takılıken deneyler gerçekleştirilmiştir.




Şekil 3.10. a) mavi kablo, b) mavi kıl sayısı azaltılmış kablo, c) mavi ezilmiş (ezik bölge kırmızı alan içerisinde) kablo, d) mavi izolasyonunda kesikler oluşturulmuş kablo, e) 3 kat beyaz kablo, f) 2 kat beyaz kablo.

Şekil 3.10, çeşitli durumda modifiye edilmiş mavi ve beyaz renkli kabloları sistematik bir şekilde göstermektedir. Bu şekil elektrik kablolarının fiziksel bütünlüklerine

yapılan müdahaleleri ve bu müdahalelerin kabloların yangın çıkarma ihtimalleri üzerine yapılan deneylerde kullanılmıştır.


2.5kvar kondansatör, deney panosuna 3.1. (c) görselindeki gibi takıldığında 13 farklı deney gerçekleştirilmiştir. Gerçekleştirilen bu deneylerde kullanılan kablolar ise Şekil 3.11.'de gösterilmiştir. Siyah renkli dışı PVC kaplı TTR kabloların her birinin kesitleri 3mm boyutundadır. Beyaz renkli kablolar ise dışı PVC kaplı TTR kabloların kesitleri ise 2 mm'dir. Beyaz kablolar 3 kat, 2 kat ve tek kat kullanılarak deneye tabi tutulmuştur. Şekil 3.9.'da gösterilen kablolardan biri ve Şekil 3.11'de gösterilen kabloların tümü 2.5kvar kondansatör takılıken deneyler gerçekleştirilmiştir. Ayrıca 2.5kvar kondansatör ile yapılan deneylerde 1.5mm ince kesitli tel de kullanılmıştır.



Şekil 3.11. a) siyah kablo, b) siyah kıl sayısı azaltılmış kablo, c) siyah ezilmiş (ezik bölge kırmızı alan içerisinde) kablo d) siyah izolasyonunda kesikler oluşturulmuş kablo, e) 3 kat beyaz kablo, f) 2 kat beyaz kablo, g) ince kablo.

Şekil 3.11, bir dizi elektrik kablosunun farklı fiziksel durumlarını görsel olarak temsil eden bir görseldir. Bu görseldeki kablolarda meydana getirilen yapısal modifikasyonlar, deneylerde yangın koşullarının oluşumuna karşı nasıl tepki verdiğini tespit etmek için kullanılmıştır. Deneyde kullanılan normal ve modifiye edilmiş kablolar ve kesitleri aşağıda Tablo.3.4.'te özet olarak verilmiştir.

Tablo 3.4. Deneyde kullanılan normal ve modifiye edilmiş kablolar.

GÖRSEL	ÖZELLİK	GÖRSEL	ÖZELLİK
	Normal kablo Kesit: 4,8mm		İnce kablo Kesit: 2mm
	Kesikli kablo Kesit: 3mm		Üç kat zil teli Kesit: 2mm x 3
	Ezik kablo (Ezik bölgesi işaretli) Kesit: 3mm		İki kat zil teli Kesit: 2mm x 2
	Lif sayısı azaltılmış kablo Kesit: 3mm		Tek kat zil teli (Önce ve Sonra) Kesit: 2mm

Tablo 3.4'te, her bir kablo tipinin kesit ölçüsü ile görsel olarak tanıtılması, kabloların yapısal özelliklerinin ve modifikasyonların görsel bir analizi için verilmiştir.

3.5. Kondansatör

Deney amaçlı kullanılan Şekil 3.1.'de gösterilen elektrik panosunda, deneylerin çeşitliliğini artırmak ve farklı elektriksel yük kapasiteleri altında yangın koşullarının oluşumunu gözlemlemek, verileri elde etmek üzere Şekil 3.12.'de gösterilen 2.5 kvar ve 5 kvar değerinde iki farklı kondansatör kullanılmıştır. Bu kondansatörler, enerji depolama kapasiteleri ve voltaj düzenleme yetenekleri açısından farklılık göstererek, deneyler sırasında çeşitli elektriksel yük senaryolarında değerlendirilmiştir.



Şekil 3.12. Deneylerde kullanılan a) 2.5kvar kondansatör, b) 5kvar kondansatör.

Şekil 3.12’de görülen kondansatörlerde farklı kablolar ile deney yapılmıştır. Her iki kondansatör de deney ortamında farklı yangın verilerini toplama ve sonraki süreçte analiz etmek için kullanılmıştır. İlk deney Şekil 25.’te görülen PVC ile kaplı, içinde birbirine sarılmış birden fazla tel demeti bulunduran 4.8mm kesitli orijinal siyah kablolardan biri ile gerçekleştirilmiştir. Bu kapsamlı deney düzenekleri, kondansatörlerin ve kabloların bu şekilde test edilmesi, pratik uygulamaların yanı sıra teorik bilginin derinleştirilmesine de katkıda bulunmuştur.


3.6. Deney Prosedürü

Deney amaçlı özel olarak tasarlanmış elektrik panosunda yürütülen deneyler, dikkatlice belirlenmiş ve sistematik bir prosedüre uygun olarak gerçekleştirilmiştir. Bu prosedür, kontaktör ve kondansatör arasında bağlantı kuran kablo üzerinde yapılan deneylerde, metodolojik bir yaklaşımı ve deney çeşitliliğini sağlamayı hedefler. Bu süreç, elektriksel bileşenlerin etkileşimlerini detaylı bir şekilde incelemek ve çeşitli elektriksel yük koşulları altında bileşenlerin yangın koşullarının oluşmasında davranış verilerini toplamak için tasarlanmıştır. Prosedür kapsamında, kontaktör ile kondansatör arasındaki kablo üzerinde gerçekleştirilen deneyler, farklı kablo türleri ve modifikasyonlar kullanarak elektriksel özelliklerin nasıl etkilendiğini sistematik bir şekilde verileri toplamak amacıyla planlanmıştır. Bu adımlar, elektrik panosunun fonksiyonelliğini, yangın koşulları parametrelerinin toplanması için kritik öneme sahiptir. Deneyler, belirli parametreler altında kontrol edilen ortamlarda yürütülerek, sonuçların güvenilirliği ve tekrarlanabilirliği maksimize edilmiştir. Bu kapsamlı deney dizisi, kontaktör ve kondansatör arasındaki elektriksel bağlantıların nasıl kurulduğunu, bu bağlantıların elektriksel performansa olan etkilerini ve olası arıza noktalarını belirlemek için önemli veriler sunar. Aşağıda deney prosedürü maddeler halinde verilmiştir.

1. Yeni deney kablosunu bağlantı yap.
2. Arduino ve Raspberry sistemlerini aktif et.
3. Panoa enerji ver.
4. Raspberry termal kamera ve IR kamera görüntü aktarımını gözlemle.
5. Kamera görüntülerinin Google Drive klasörüne aktarımını kontrol et.
6. Merkez bilgisayarda Matlab arayüzünü çalıştır.
7. Thingspeak.com üzerinde verilerin akışını kontrol et.
8. Verilerin Matlab arayüzüne aktarımını kontrol et.
9. Raporlama ekranını çalıştır.
10. Raporlanan verilerden ilgili bir veriyi seç.
11. İlgili verinin görüntü işleme resimlerini kontrol et.
12. Raporlanan verilerin histogram ve korelasyon çizimlerini incele.
13. 40 dakika – 60 dakika arası verilerin aktarılmasını sağla.
14. Pano enerjisini kapat.
15. Arduino ve Raspberry sistemlerini pasif yap.
16. Deneyi sonlandır.
17. Bir sonraki deney için sistemin soğumasını bekle (en az 2 saat)

5kvar kondansatör ile yapılan tüm deneyler tamamlandıktan sonra 5kvar kondansatör yerinden sökülmüş ve 2.5kvar kondansatör takılmıştır. Yukarıdaki sıralamalar aynı şekilde tüm kablo deneyleri için uygulanmıştır. Deney esnasında verilerin toplanması için Arduino Mega mikro denetleyici ve Raspberry Pi 4 mini bilgisayar kullanılmıştır. Arduino Mega elektrik panosu üzerine sabitlenmiş ve pano içerisine uzatılan kablolar ile pano içerisinde oluşan ortam sıcaklık değeri, nem değeri, hava kalitesine etki eden zehirleyici gaz karbonmonoksit ve basit boğucu gaz karbondioksit ölçümleri yapılmıştır. Ortam sıcaklığı ve nemi DHT22 modülü ile gaz ölçümleri ise MQ135 ve MQ4 ile yapılmıştır. Ayrıca pano içindeki kontaktör kablosuna akım kelepçesi takılmıştır. Akım ve voltaj değerleri PZEM-004T modülü ile okunmuştur. Arduino Mega kablosuz bağlantı ile iletişim kurması içinse ESP-8266 modülü kullanılmıştır. Raspberry Pi 4 elektrik panosu yanına yerleştirilmiş ve pano içerisine uzatılan kablolar ile MLX90640 kızılötesi termal kamera pano içerisine sabitlenmiştir. Ayrıca Raspberry Pi 4 ile dış ortam sıcaklık ve nem değerleri DHT22 modülü ile ölçülmüştür. Raspberry Pi 4 ethernet kartı üzerinden kablolu internet bağlantısı kurulmuştur.

Arduino Mega ve Raspberry Pi 4 için sistem anlatımını gösteren blok diyagram şeması Şekil 3.13.'te verilmiştir.



Şekil 3.13. Blok diyagram şeması.


Şekil 3.13, sensörler, güç kaynağı, veri işleme ekipmanı, iletişim ekipmanı ve bulut sistem ile iletişim araçlarını içeren bir blok diyagram şemasını göstermektedir. Bu şema, Arduino Mega ve Raspberry Pi 4 sistemlerindeki bileşenler arasındaki ilişkileri ve etkileşimleri görsel olarak temsil etmek için kullanılmıştır. Blok diyagram, karmaşık sistemlerin anlaşılmasını kolaylaştırmaktadır.

3.7. Deney verilerinin Nesnelerin İnterneti (IoT) ile ThingSpeak Bulut sistemine aktarılması

IoT metodu kullanılarak haberleşme sağlanması MATLAB programının da desteklemiş olduğu thingspeak.com üzerinden sağlanmıştır. ThingSpeak, ticari olmayan küçük projeler için ücretsiz bir hizmet olarak mevcuttur (<3 milyon mesaj/yıl veya ~8.200 mesaj/gün). Benzer birkaç IoT destekleyici (Mesaj sorgusu Telemetry Aktarımı (MQTT) - Firebase) internet sitesi de bulunmaktadır. Fakat bunlar ve benzerleri hem ücret talep etmekte hem de veri tabanı desteğinde çeşitli iletişim sorunları çıkarabilmektedir.

IoT, farklı cihazların ve sensörlerin internet üzerinden veri toplayıp bu verileri merkezi bir sunucuya aktarmasını sağlayan bir teknolojidir. Bu süreç, çeşitli platformlar aracılığıyla gerçekleştirilebilir ve MATLAB programı da bu platformlardan biri olan Thingspeak.com bulut sistemini destekler. ThingSpeak, özellikle ticari olmayan, küçük ölçekli projeler için ücretsiz bir hizmet sağlayarak yılda 3 milyon mesaja kadar veya günlük yaklaşık 8.200 mesaj kapasitesi ile veri iletişimi ve analizi yapma imkânı sunar. ThingSpeak, MATLAB entegrasyonu sayesinde, veri analizi ve görselleştirme işlemlerini kolaylaştırır, bu da kullanıcıların veriler üzerinde karmaşık hesaplamalar yapmasına ve bu verileri etkili bir şekilde işlemesine olanak tanır. Diğer yandan, benzer IoT destekleyici internet siteleri arasında MQTT, Firebase gibi platformlar bulunmaktadır. Bu tür platformlar genellikle daha geniş özellikler sunar ve bazı

durumlarda ticari kullanımlar için daha uygun olabilir. Ancak, bu platformların kullanımı ücretlidir. Küçük ve ticari olmayan projeler için, ücretsiz ve bütünleşmiş araçlar sunan Thingspeak gibi platformlar ideal olabilirken, daha büyük ölçekli veya ticari projeler için MQTT veya Firebase gibi alternatifler daha uygun olabilir. Bu seçim, proje bütçesi, gereksinimleri ve beklenen kullanım ölçeğine bağlı olarak değerlendirilmelidir. Aşağıdaki Şekil 3.14.'te IoT altyapısının Thingspeak ile iletişimini içeren görsel paylaşılmıştır




Şekil 3.14. Nesnelerin interneti (IoT) altyapısının ThinkSpeak ile oluşturulması.

Şekil 3.14, IoT altyapısının ThingSpeak platformu kullanılarak nasıl oluşturulduğunu gösteren şemayı göstermektedir. Bu görsel, IoT cihazlarından veri akışının başladığı noktadan, verilerin işlendiği ve analiz edildiği son aşamaya kadar olan süreci adım adım açıklar. ThingSpeak MATLAB entegrasyonu sayesinde, daha karmaşık veri analizi ve görselleştirme işlemleri gerçekleştirilebilir. Kullanıcılar MATLAB'in geniş fonksiyon kütüphanesini kullanarak veriler üzerinde detaylı analizler yapabilir ve bu analizlerin sonuçlarını görsel grafiklerle sunabilir. Aşağıdaki Şekil 3.15.'te ThingSpeak platformuna sensörlerden elde edilen verilerin üzerine gönderilmesi ve bu verilerin grafik gösterimleri yer almaktadır.



(a)



(b)


Şekil 3.15. Verilerin (a)Arduino Mega ile Esp8266 WiFi modülü, (b)Raspberr Pi ve WiFi özelliği kullanılarak ThingSpeak platformuna gönderilmesi.

Şekil 3.15 iki farklı donanım konfigürasyonu kullanarak ThingSpeak platformuna gönderilmiş verilerin bazılarını içermektedir. Bu iki konfigürasyon, (a) Arduino Mega mikrokontrolcü ve ESP8266 WiFi modülü kombinasyonu ile (b) Raspberry Pi 4 ve onun yerleşik WiFi özelliği aracılığıyla gerçekleştirilmektedir. Her iki sistem de IoT uygulamaları için veri toplama ve iletimi açısından önemli örnekler sunar.

3.8. Ana makinede verileri işleme

Bu çalışmada, Matlab yazılımı kullanılarak geliştirilen ve ThingSpeak platformu üzerinden veri çekme işlemlerini içeren bir kullanıcı arayüzü tasarlanmıştır. ThingSpeak, IoT cihazlarından veri toplama ve analiz etme imkânı sunan bir bulut tabanlı uygulamadır. Geliştirilen sistem, bu platform üzerinde depolanan verilere Matlab ortamından erişilmesine olanak tanıyan bir yapıdadır. Veri erişim süreci, ThingSpeak tarafından sağlanan özel bir API anahtarı aracılığıyla gerçekleştirilmektedir. Bu anahtar, veri güvenliğini sağlamak ve yetkisiz erişimleri önlemek amacıyla kullanılmaktadır. Arayüz, kullanıcının verileri anlık olarak izleyebilmesi için tasarlanmıştır. Sol tarafta konumlanan bölümde, veriler her 30 saniyede bir otomatik olarak yenilenmektedir, böylece kullanıcılar en güncel bilgilere hızla ulaşabilmektedir. Ayrıca, bu veriler hem sayısal hem de grafiksel formatlarda sunulmaktadır. Grafik üzerinde, belirlenen limit değerlerini aşan durumlar için kırmızı

Arayüzün sağ tarafında yer alan raporlama ekranında ise kullanıcılar tarafından belirlenen zaman aralıklarına göre verilerin raporlanması mümkündür. Günlük, haftalık, yarı aylık ve aylık olmak üzere farklı zaman dilimleri için verilerin analizi ve raporlanması sağlanmaktadır. Ek olarak, rapor ekranında listelenen veri noktalarına tıklanıldığında ilgili verinin termal kamera görüntüsü açılmaktadır. Termal ve IR kamera görüntüleri, görüntü işleme teknikleri olan threshold ve Otsu metotları kullanılarak işlenmektedir. Bu işlem, görüntülerdeki önemli özelliklerin belirginleştirilmesine ve daha net analiz yapılabilmesine yardımcı olmaktadır. Sonuç olarak, geliştirilen Matlab arayüzü, kullanıcıların veri takibi ve analiz işlemlerini kolaylaştırmakta, ayrıca görsel ve işlevsel araçlarla zenginleştirilmiş bir deneyim sunmaktadır. Bu arayüz, özellikle endüstriyel uygulamalar ve araştırma faaliyetleri için değerli bir kaynak olarak ön plana çıkmaktadır. Bu çalışmanın detayları, ilgili arayüz ekranının bir görseli ile birlikte Şekil 3.16.'da sunulmuştur.



Şekil 3.16, Matlab'ın uygulama geliştirme (Application Designer) aracı kullanılarak oluşturulan bir kullanıcı arayüzünü göstermektedir. Bu arayüz, ThingSpeak üzerinden alınan verilerin çağrılmasını ve görselleştirilmesini sağlar. Tasarım, veri izleme ve analiz işlemlerini kolaylaştırmak amacıyla kullanıcı dostu bir biçimde düzenlenmiştir. Bu özellikleriyle birlikte, kompleks veri kümelerinin yönetilmesi ve analiz edilmesi

süreçlerinde etkili bir araç olarak öne çıkar. Kullanıcılar için interaktif ve bütünlük bir deneyim sunarak, bulut tabanlı karar verme süreçlerini destekler.

Bu çalışmada, Raspberry Pi 4 kullanılarak, belirli zaman aralıklarında termal ve NOIR kamera görüntülerinin otomatik olarak kaydedilmesi ve saklanması süreci incelenmiştir. Raspberry Pi 4, yaklaşık olarak her 5 ila 7 saniyede bir, elde edilen görüntüleri Google Drive hesabına yüklemektedir. Bu işlem, el sıkışma (Handshake) protokolünün gecikme sürelerini dikkate alarak optimize edilmiştir. El sıkışma protokolü, cihazlar arası veri iletimi sırasında güvenliğin ve veri bütünlüğünün sağlanmasında kritik bir role sahiptir; bu protokol aynı zamanda iletim sürelerindeki gecikmeleri de minimize etmek için tasarlanmıştır. Raspberry Pi 4 ayrıca, toplanan görüntüleri yerel hafızasında da saklamaktadır. Bu, veri kaybı veya iletim sırasında oluşabilecek sorunlara karşı bir güvenlik önlemi olarak işlev görür ve verilere yerel olarak erişim imkânı tanır. Yerel saklama çözümü, aynı zamanda verilerin analiz edilmesi ve işlenmesi için gerekli esnekliği ve hızı sağlar. İlgili çalışma kapsamında elde edilen termal ve IR kamera görüntüleri, Şekil 3.17’de örneklendirilmiştir. Bu görüntüler, pano içerisindeki sıcaklık dağılımını ve ısı kaynaklarını görsel olarak sergileyerek, ekipmanların çalışma performanslarının ve durumlarının izlenmesine imkân tanır. Bu görüntülerin düzenli olarak Google Drive’a yüklenmesi, verilere uzaktan erişim sağlanmasını ve birden fazla kullanıcı tarafından kolayca incelenebilmesini mümkün kılar. Ayrıca, bu entegrasyon sayesinde, büyük veri kümelerinin depolanması ve yönetilmesi daha verimli bir hale gelir. Böylece, veriler üzerinde daha kapsamlı analizler yapılabilir ve daha doğru kararlar alınabilir.




Şekil 3.17. Matlab appdesigner raporlama ekranındaki ilgili satıra ait pano resimlerinin Google Drive üzerinden çağırılması.

Şekil 3.17., Matlab'ın App Designer araç kümesi kullanılarak geliştirilen raporlama ekranını detaylı bir şekilde göstermektedir. Bu arayüz, kullanıcıların Google Drive

üzerinden kaydedilen pano resimlerine erişimini sağlamak için tasarlanmıştır. Raporlama ekranı, kullanıcılara çeşitli tarih ve zaman dilimlerine ait veri kayıtlarını görüntüleme olanağı tanır. Bu kayıtlar arasında seçim yapıldığında, seçili veriye ait pano resimleri otomatik olarak çağrılmaktadır. Raporlama ekranının bu işlevselliği, özellikle sürekli izleme ve bakım gerektiren tesislerde, arızaların önlenmesi, bakım süreçlerinin planlanması ve operasyonel verimliliğin artırılması açısından büyük önem taşımaktadır. Kullanıcılar, bu sayede zaman ve maliyetten tasarruf sağlayarak, ekipman sağlığını sürekli olarak izleyebilir ve potansiyel sorunları erkenden tespit edebilir.

Aşağıdaki Şekil 3.18.'de, belirli bir zaman diliminde kaydedilen termal ve IR kamera görüntülerinin renk filtreleme ve görüntü işleme teknikleri uygulanarak elde edilen sonuçları göstermektedir. Bu görselde, kırmızı, yeşil ve mavi renk filtreleri uygulanmış resimlerin yanı sıra, kırmızı ve yeşil filtrelenmiş görüntüler üzerinde threshold ve Otsu metotlarıyla yapılan görüntü işlemleri detaylı bir şekilde sergilenmektedir. Bu işlemler, görüntülerdeki özellikleri belirginleştirmek ve daha net analiz yapabilmek için kullanılmaktadır.



Şekil 3.18. Matlab uygulama tasarlayıcı ekranı ile tasarlanmış raporlama ekranına ait ilgili resmin görüntü filtreleri.

Şekil 3.18.'te yer alan işleme teknikleri, görüntülerdeki kontrastı artırarak nesneler arası farklılıkları daha ayrıntılı bir şekilde gözlemlemeyi sağlar. Threshold metodu, belirli bir eşik değeri belirleyerek, bu değerin üzerindeki pikselleri beyaz, altındakileri ise siyah olarak işaretler. Bu çalışmada, özellikle sıcaklık farklarını vurgulamak için kullanılmıştır. Otsu metodu ise, görüntüdeki gri tonlarının histogramını analiz ederek, arka plan ve nesne arasında en iyi ayrımı sağlayacak eşik değerini otomatik olarak hesaplar. Bu yöntem, daha karmaşık ve değişken aydınlatma koşullarında etkili bir şekilde çalışır.

Şekil 3.18.'de yer alan görüntülerin dosya boyutlarına gelince, termal kamera görüntüsü 11 kilobayt (kB), IR kamera görüntüsü ise 105 kB boyutunda kaydedilmiştir. Bu veriler dikkate alındığında, bir gün boyunca saklanacak görsellerin toplam boyutunun yaklaşık 1 ile 2 gigabayt (GB) arasında değiştiği hesaplanmıştır. Yıllık depolama ihtiyacı ise, bu oranlara dayanarak, yaklaşık 366 GB ile 732 GB arasında bir alan kaplayacaktır. Bu hesaplamalar, veri depolama stratejilerinin planlanması ve gerekli altyapının oluşturulması açısından önemli bilgiler sunmaktadır. Bu koşulları özetler durum Tablo 3.5.'te açıklanmıştır.

Tablo 3.5. Termal ve NOIR Kamera Görüntülerinin Dosya Boyutları ile Günlük ve Yıllık Depolama İhtiyaçlarının Hesaplanması

Görüntü Türü	Dosya Boyutu (kB)	Günlük Görüntü Sayısı	Günlük Depolama İhtiyacı (GB)	Yıllık Depolama İhtiyacı (GB)
Termal Kamera	11	(5-10 saniye aralığı, örnek: 8640)	0.095	34.71
NOIR Kamera	105	(5-10 saniye aralığı, örnek: 8640)	0.906	330.69
Toplam	-	-	1 - 2	366 - 732

Tablo 3.5, termal ve NOIR kamera görüntülerinin depolama ihtiyaçlarını yönetmek için gerekli olan stratejik planlama ve altyapı düzenlemelerinde kullanılabilecek önemli verileri sağlar. Veri depolama kapasitesi ve bant genişliği planlamaları, bu tür detaylı hesaplamalar ile optimize edilebilir, böylece kaynakların daha verimli kullanımı mümkün olur.

3.9. Deney verileri

Bilim insanların yaptığı çalışmalarda ısı salınım grafiği çeşitlilik gösterse de temelde aynı durum paylaşılmıştır. Bir çalışmada, termoplastik poliüretan elastomerde para-aramid elyafın yangın güvenliğini iyileştirmesi için çalışılmış ve termoplastik poliüretan, para-aramid elyaf HRR karşılaştırılması yapılmıştır. (Chen, X., ve ark. 2017).). Farklı bir çalışmada ise, tünel yangınlarında ortaya çıkan HRR koşulları incelenmiştir (Ingason, H., 2009).). Bu çalışmada, tehlikesiz yük taşıyan bir ağır vasıtanın tünel içerisinde yanması koşulu simüle edilmiş ve HRR eğrisi oluşturulmuştur.

Şekil 9.’daki değerlendirmeye göre Normal (N) koşulları, Sınıf1 (S1) ignition öncesi koşulları, Sınıf2 (S2) ignition - flashover arası koşulları, Sınıf3 (S3) flashover – decay arası koşulları, Sınıf4 (S4) decay sonrası koşulları ifade eder. Bu bilgilere göre yaptığımız deneylerde elde edilen bulgulara ait veriler Tablo 3.6.’da verilmiştir.

Tablo 3.6 Deney aşamalarına göre Arduino Mega ve Raspberry Pi 4 verilerinin değerleri

	Arduino Mega	Raspberry Pi 4
N	3025	3025
S1	453	453
S2	8	8
S3	16	16
S4	19	19
Toplam	3521	3521

Tablo 3.6, deneylerinin farklı aşamalarında Arduino Mega’nın ve Raspberry Pi 4 performans verilerini karşılaştırmalı olarak sunmaktadır. Deneyler, normal koşullar (N), yanma öncesi (S1), yanma ile flashover arası (S2), yangının gelişme aşamasına (S3) ve sonrası (S4) ise korlanma sönme koşullarını içermekte olup, her bir aşamada elde edilen veri sayıları belirtilmiştir. Her iki cihaz için de toplam veri sayısı 3521 olarak kaydedilmiş, bu durum cihazların her aşamadaki tutarlı performansını göstermektedir. Bu veriler, ML teknikleriyle yangın simülasyonunu değerlendirmek için kullanılmıştır. Gereksiz ve alakasız özelliklerin öğrenme modellerinin performansını etkilediği farklı çalışmalarda da gözlemlenmiştir (Taha, A., ve ark. 2023). Dolayısıyla verilerin temizliğinde özellik seçimi kullanılmıştır. Dolayısıyla ML tekniklerinde S2i S3 ve S4 yeterli veri oluşturmadığı için çıkarılmış ve yangın öncesi koşulların izlenmesine yönelik çalışma yapılmıştır. Kısaca yangın koşulunun oluşup oluşmadığına karar verme sürecine odaklanılmıştır. Böylelikle 3478 satırdan meydana gelen veri kümesi kullanılmıştır.

2023-01-19 tarihinde yapılan deneyde kablodaki sıcaklık başlangıçta hızlıca arttığı, daha sonra rejim noktasına ulaşmaya başlayınca artışı hızının azaldığı fakat artma eğiliminin devam ettiği gözlemlenmiştir. Arduino Mega’dan ve Raspberry Pi 4 elde edilen veriler Tablo 3.7.’de örneklem küme olarak paylaşılmıştır.


Tablo 3.7. Arduino Mega ve Raspberry Pi örnek veriler

Arduino Mega							Raspberry Pi 4		
Tarih Saat	Pano İçi Sıcaklık (°C)	Pano İçi Nem %	CO	CO ₂	Voltaj (Volt)	Akım (Amper)	Kablo Sıcaklık (°C)	Dış Ortam Sıcaklık (°C)	Dış Ortam Nem %
2023.01.19 10:51:15	22,8	41,6	3,1	402,39	228,5	11,13	24,2	22	31
2023.01.19 11:05:08	26,7	33,4	2,52	402,06	229,6	11,27	26,7	22	28
2023.01.19 11:32:38	28,3	30,5	2,76	402,19	228,6	11,19	27,6	22	27
2023.01.19 12:00:15	28,8	29,4	2,18	401,85	229	11,24	28,1	22	26
2023.01.19 12:28:03	29,4	28,6	1,97	401,72	227,2	11,15	28,6	24	26

Tablo 3.7, Arduino Mega ve Raspberry Pi 4 kullanılarak elde edilen çeşitli deneysel verilerini belirli tarih ve zamanlarda sunmaktadır. Ölçülen parametreler arasında pano içi sıcaklık, pano içi nem, karbon monoksit (CO), karbon dioksit (CO₂) seviyeleri, voltaj, akım, kablo sıcaklığı, dış ortam sıcaklığı ve dış ortam nemi bulunmaktadır.


Çalışmada gerçekleştirilen toplam deneylerden yedi tanesinde yanma veya patlama olayları gözlemlenmiştir. Bu olaylar, deneyler sırasında kullanılan kabloların zorlayıcı modifiye edilmiş koşullara maruz kalması sonucu meydana gelmiştir. İlgili deneylerde meydana gelen bu kritik olaylar, yangın meydana gelmeden önceki koşulların incelenmesi için önemli veriler sağlamaktadır. Yanma ve patlama sonucu etkilenen kabloların görsel incelemeleri yapılmış ve bu görseller Şekil 34 ve Şekil 35'te detaylı bir şekilde sunulmuştur. Bu görsellerde kabloların yanma sonrası durumları, yanma özellikleri ve hasar seviyeleri gözler önüne serilmiştir.

Gerçekleştirilen deneylerin yedi tanesinde yanma veya patlama gerçekleşmiştir. Bu deneylerin kablo görselleri Şekil 3.19. ve Şekil 3.20.' da verilmiştir.



Şekil 3.19. (a) 5kvar beyaz kablo, (b) 2,5 kvar 5 tel eksiltilmiş beyaz kablo, (c) 2,5 kvar 8 tel eksiltilmiş beyaz kablo (d) 2,5 kvar 6 tel eksiltilmiş beyaz kablo.

Şekil 3.19, farklı modifikasyonlara tabi tutulmuş ve sonrasında deneylerde kullanılmış kabloların görsellerini içermektedir. Şekil 3.19. (a) görselindeki kablo patlama sonucunda bu hale gelmiştir. Şekil 3.19. (b), (c) ve (d) görsellerindeki kablolarda ise yanma meydana gelmiştir. Benzer koşullara ait görsel Şekil 3.20.'de verilmiştir.




Şekil 3.20. (e) ince kablo, (f) 2,5 kvar 6 tel eksiltilmiş beyaz kablo (deney 2) (g) 2,5 kvar 7 tel eksiltilmiş beyaz kablo .

Şekil 3.20, farklı modifikasyonlara tabi tutulmuş ve sonrasında deneylerde kullanılmış üç farklı kablo örneğinin görsellerini içerir. Şekil 3.20. (e), (f) ve (g) görsellerindeki kablolarda yanma meydana gelmiştir. Aşağıdaki Tablo 3.8.'de ise Şekil 3.19 (a) 5kvar beyaz kablo deneyinde elde edilen veriler paylaşılmıştır.

Tablo 3.8. 5kvar beyaz kablo deneyi verileri.

Tarih Saat	Arduino Mega						Raspberry Pi 4		
	Pano İçi Sıcaklık (°C)	Pano İçi Nem %	CO	CO ₂	Voltaj (Volt)	Akım (Amper)	Kablo Sıcaklık (°C)	Dış Ortam Sıcaklık (°C)	Dış Ortam Nem %
2023-01-13 11:37:30	20,30	49,30	1,52	401,40	226,00	22,38	24,06	20	45
2023-01-13 11:37:47	20,40	49,50	16,31	407,99	226,40	22,38	29,00	20	45
2023-01-13 11:38:04	20,80	49,00	169,40	443,78	226,40	22,38	39,06	20	45
2023-01- 1311:38:21	22,40	54,40	164,26	442,81	225,40	0,00	22,02	20	45
2023-01- 1311:38:38	23,80	47,20	37,67	414,68	226,30	0,00	22,03	20	44

Tablo 3.8, Şekil 3.19. (a) 5 kvar beyaz kablo deneyinden elde edilen verileri sunmaktadır. Bu tablo, Arduino Mega ve Raspberry Pi 4 kullanılarak yapılan deneyler sırasında, birkaç dakika içinde yapılan ölçümleri ardışık zaman dilimlerinde göstermektedir. Aşağıdaki Şekil 3.21'de Şekil 3.19 (a) 5kvar beyaz kablo deneyinde elde edilen sonuçlara ait kızılötesi termal kamera görüntüleri paylaşılmıştır.



Şekil 3.21. 5kvar beyaz kablo deney termal kamera görüntüleri.

Şekil 3.21, 5 kvar kapasiteye sahip kondansatör ile yapılan deneyde kullanılan beyaz kablunun termal kamera ile çekilmiş görüntülerini sergilemektedir. Bu görüntüler, kabloda meydana gelen ısı değişimlerini ve sıcaklık dağılımını detaylı bir şekilde göstermektedir. Aşağıdaki Şekil 3.22.'de Şekil 3.19. (a) 5kvar beyaz kablo deneyinde elde edilen sonuçlara ait NOIR kamera görüntüleri paylaşılmıştır.



Şekil 3.22. 5kvar beyaz kablo deneyinden elde edilen NOIR kamera görüntüleri

Şekil 3.22, Şekil 3.20.'nin (a) bölümünde yer alan 5 kvar beyaz kablo deneyinden elde edilen NOIR (no infrared) kamera görüntülerini içermektedir. Bu kamera, kullandığı görüntüleme teknolojisi gereği infrared ışık spektrumunu filtreleyerek sadece görünür ışıkla çekim yapılmasını ifade eder. Bu şekilde, kablo üzerindeki termal etkiler veya ısı dağılımları yerine, kablo üzerinde meydana gelen görünür ışık değişiklikleri ve bu değişikliklerin neden olduğu görüntüler detaylı olarak incelenebilir. Yoğun duman oluşumu ilgili görselde kırmızı renk ile belirtilmiştir. Aşağıdaki Şekil 3.23.'te ise Şekil

3.19. (a) 5kvar beyaz kablo deneyi sırasında elde edilen, cep telefonu kamerası ile çekilen videoya ait görüntüleri içermektedir.




Şekil 3.23. Deney sırasında yanma ve patlama koşullarını gösteren görüntüler.

Şekil 3.23, yapılan deney sırasında meydana gelen fiziksel değişiklikler, yanma ve patlama koşulları gözlemlenebilmektedir. Bu görüntüler, deney ortamında kullanılan kablounun aşırı sıcaklık sebebiyle nasıl tepki verdiğini belgelemek amacıyla çekilmiştir. Aşağıdaki Tablo 3.9.'de ise farklı bir deney olan Şekil 3.20 (g) 2,5kvar, 7 tel eksiltilmiş beyaz kablo deneyi esnasında elde edilen yanma görüntüleri paylaşılmıştır.


Tablo 3.9. 2,5kvar, 7 tel eksiltiilmiş beyaz kablo deneyi verileri.

Arduino Mega							Raspberry Pi 4		
Tarih Saat	Pano İçi Sıcaklık (°C)	Pano İçi Nem%	CO	CO ₂	Voltaaj (Volt)	Akım (Amper)	Kablo Sıcaklık (°C)	Dış Ortam Sıcaklık (°C)	Dış Ortam Nem %
2023-01-24 07:00:55	21,40	46,10	2,54	402,07	230,70	11,28	22,0	20	36
2023-01-24 07:01:18	21,40	46,30	2,49	402,04	230,60	11,24	26,4	20	36
2023-01-24 07:01:35	21,60	46,20	3,2	402,34	230,90	11,27	27,5	20	36
2023-01-24 07:01:52	21,80	46,00	5,14	403,45	230,80	11,26	28,2	20	36
2023-01-24 07:02:14	22,10	45,50	8,25	404,87	230,80	11,27	29,2	20	36
2023-01-24 07:02:32	22,30	45,00	12,59	406,62	230,80	11,27	30,1	20	36
2023-01-24 07:02:49	22,60	44,50	18,37	408,71	230,60	11,23	30,9	21	36
2023-01-24 07:03:06	22,90	44,10	24,15	410,62	229,70	11,21	30,8	20	36
2023-01-24 07:03:23	23,1	43,60	31,65	412,93	230,80	11,21	31,2	20	36
2023-01-24 07:03:40	23,40	43,10	37,05	414,50	231,00	11,25	31,4	21	36
2023-01-24 07:03:57	23,70	42,60	49,10	417,79	231,20	11,25	34,2	20	36

Tablo 3.9., Şekil 3.20. (g) 2,5kvar kapasiteli, 7 tel eksiltiilmiş beyaz kablo deney panosuna takılı iken elde edilmiş verileri içermektedir. Deneyin gerçekleştirildiği zaman içerisinde artan kablo sıcaklık, nem, CO ve CO₂ seviyeleri dikkat çekicidir. Aşağıdaki Şekil 3.24.'te ise Tablo 3.9.'da yer alan zaman dilimine karşılık gelen veriler için termal kamera görüntüleri verilmiştir.

**Şekil 3.24.** 2,5kvar 7 tel eksiltiilmiş beyaz kablo deney termal kamera görüntüleri.

Şekil 3.24. 2,5 kvar kapasiteli ve 7 tel eksiltilmiş beyaz bir kablonun termal kamera ile çekilmiş görüntülerini içermektedir (Şekil 3.20. (g)). Bu görüntüler, kablonun deney süreci boyunca maruz kaldığı termal değişimleri gözlemlemek için kullanılmıştır. Termal kamera, kablo üzerindeki sıcaklık dağılımını renklerle ifade eder, böylece yüksek sıcaklık alanları daha parlak renklerle, düşük sıcaklık alanları ise daha soğuk renklerle gösterilmiştir. Bu termal görüntüler, kablonun elektrik akımı taşıması sırasında ortaya çıkan ısıyı ve bu ısının kablonun çeşitli bölümlerinde nasıl dağıldığını görselleştirir. Aşağıdaki Şekil 3.25.'te ise Şekil 3.24.'te yer alan termal görüntülere eşlenik gelen, NOIR kamera görüntülerini içermektedir.



Şekil 3.25. 2,5kvar 7 tel eksiltilmiş beyaz kablo deney NOIR kamera görüntüleri.

Şekil 3.25, Şekil 3.20. (g) bölümünde yer alan 2,5kvar 7 tel eksiltilmiş beyaz kablo deneyinden elde edilen NOIR (no infrared) kamera görüntülerini içermektedir. Bu kamera, kullandığı görüntüleme teknolojisi gereği kızılötesi ışık spektrumunu filtreleyerek sadece görünür ışıyla çekim yapılmasını ifade eder. Bu şekilde, kablo üzerindeki termal etkiler veya ısı dağılımları yerine, kablo üzerinde meydana gelen görünür ışık değişiklikleri ve bu değişikliklerin neden olduğu görüntüler detaylı olarak incelenebilir. Yoğun duman oluşumu ilgili görselde kırmızı renk ile belirtilmiştir. Aşağıdaki Şekil 3.26.'da ise Şekil 3.20. (g)'de yanmış hali gösterilen 2,5kvar beyaz kablo deneyi sırasında elde edilen, cep telefonu kamerası ile çekilen videoya ait görüntüleri içermektedir. Yoğun duman oluşumu ilgili görselde kırmızı renk ile belirtilmiştir.




Şekil 3.26. 2,5kvar, 7 tel eksiltilmiş beyaz kablo deneyinde meydana gelen yanma koşullarını gösteren görüntüler.

Şekil 3.26, yapılan deney sırasında meydana gelen fiziksel değişiklikler ve yanma koşulları gözlemlenebilmektedir. Bu görüntüler, deney ortamında kullanılan kablonun aşırı sıcaklık sebebiyle nasıl tepki verdiğini belgelemek amacıyla çekilmiştir.




4. DENEY VERİLERİNİN MAKİNE ÖĞRENİMİ (ML) METODU İLE İŞLENMESİ VE PERFORMANS DEĞERLENDİRME

Elde edilen deney verilerinin analizi bilimsel araştırmaların temel bir bileşenidir ve bu süreç, verilerin doğruluğu ve yorumlanması açısından kritik öneme sahiptir. Bu bölümde, Matlab R2023b akademik versiyonu kullanılarak deney verilerinin nasıl işlendiğini anlatılmıştır. Matlab programının ML bölümünün denetimli öğrenme yöntemlerine ait çeşitli sınıflandırma metotlarından yararlanarak deney verilerinin değerlendirilmesi ele alınmıştır. Elde edilen sonuçlar, grafik ve tablolar halinde görselleştirilmiştir. Bu görselleştirmeler, model performansını ve sınıflandırma sonuçlarını daha anlaşılır hale getirir. Uygulama süreci aşağıdaki Şekil 4.1.'de Matlab uygulama sekmesinde yer alan sınıflandırma öğrenimi tuşuna basılmasıyla başlar.




Şekil 4.1. Matlab sınıflandırma öğrenimi.

Şekil 4.1.'de görülen sınıflandırma öğrenimi, denetimli ML tekniklerini kullanarak verileri sınıflandırmak amacıyla modellerin eğitilmesini sağlar. Bu süreç, deney verileri kümesine ait sınıflandırılmış örnekleri içerir ve bu örnekler, algoritmaların belirlenmiş sınıflara ait tahmin yeteneklerini geliştirmesi için kullanılır. Sınıflandırma öğrenimi, karmaşık veri yapılarından anlamlı bilgiler çıkarılabilmesi için kritiktir ve modellerin kullanımı, çeşitli uygulama alanlarında verimliliği ve doğruluğu artırma potansiyeline sahiptir. Aşağıdaki Şekil 4.2.'de eğitimi sürecinin başlaması için verilerin yüklenme aşaması gösterilmiştir.



Şekil 4.2. Deney verilerinin Matlab programına yükleme.

Şekil 4.2, deney verilerinin Matlab programına yükleme süreci ilgili excel dosyasının bağlantı yolunun dosyadan okutulmasıyla başlar ve aşağıdaki Şekil 4.3.'te yer alan veri yükleme arayüzündeki ilgili verilerin seçilmesiyle devam eder.




Kategorik seçim olarak arduino_durum uygulanmıştır. Diğerleri ise sayısal veri niteliğinde aktarım yapılmıştır. Toplam 3478 veri satırı aktarılmıştır.

Algoritmalar, her bir girdi için bir çıktı sınıfı üretecek şekilde öğrenirken, öğrenme modelinin doğruluğu, çapraz doğrulama gibi yöntemlerle değerlendirilir. Bu yöntem, modelin genel veri kümesi üzerindeki performansını objektif bir biçimde ölçmek için kullanılan bir tekniktir. Eğitim süreci boyunca, özellik seçimi gibi çeşitli optimizasyon teknikleri uygulanır, böylece modelin hem eğitim hem de yeni, görülmemiş veriler üzerinde maksimum performans göstermesi sağlanır. Aşağıdaki Şekil 4.4. doğrulama tekniklerinin hangisinin kullanılmasını seçim ekranıdır.

Name	Type	Range
pano_ortam_sicakligi	double	20.2 .. 33.8
arduino_nem	double	25.1 .. 49.8
co	double	0.07 .. 16.31
co2	double	400.15 .. 407.99
voltaj	double	222.9 .. 231.5
akim	double	0 .. 23.01

Şekil 4.4. Doğrulama tekniği seçim ekranı.

Bu çalışmada, Şekil 4.4.'te de gösterildiği üzere, 5 katlı çapraz doğrulama (5 k-fold cross-validation) tekniği tercih edilmiştir. Toplamda 3478 veri satırı içeren veri kümesi üzerinden yapılan bu seçim, veri kümesinin %80'lik bir kısmının modelin eğitimi için, kalan %20'lik kısmının ise modelin performansının test edilmesi için ayrılmasını öngörür. Çapraz doğrulama tekniği, her bir alt veri kümesinin hem eğitim hem de test amaçlı kullanılmasını sağlayarak modelin genelleştirme yeteneğini daha etkin bir şekilde değerlendirmeye olanak tanır. Bu yaklaşım, modelin farklı veri alt kümeleri üzerindeki performansını test etmek ve böylece aşırı öğrenme gibi riskleri minimize etmek için kullanılır. Aşağıdaki Şekil 4.5.'te özellik seçimi ekranı yer almaktadır. Bu ekranda, MaMi, Ki-Kare, RelifF, Varyans analizi (Anova), Kruskal Wallis istatistiksel analiz teknikleri yer almaktadır. Bu çalışmada varyans analizi seçilmiştir.



Şekil 4.5. Matlab istatistiksel analiz yöntemi seçim ekranı.

Bu çalışmada, Şekil 4.5'te gösterildiği üzere, özellik seçimi için varyans analizi yöntemi kullanılmıştır. Varyans analizi, mevcut dokuz özelliğin etkilerini en yüksekten en düşüğe doğru sıralayarak, her birinin model üzerindeki etkisini değerlendirmekte ve önceliklendirme sağlamaktadır. Sıralama şu şekilde gerçekleştirilmiştir: 1. CO, 2. CO₂, 3. kablo sıcaklık, 4. pano ortam sıcaklık, 5. arduino nem (pano ortam nemi), 6. dış ortam sıcaklık, 7. akım, 8. raspberry nem ve 9. voltaj. Bu analiz sonucunda, öğrenim ve test süreçleri için yüksek öneme sahip olduğu değerlendirilen ilk beş özellik (CO, CO₂, kablo sıcaklık, pano ortam sıcaklık, arduino nem) seçilmiştir. Bu özelliklerin seçimi, modelin performansını doğrudan etkileyen faktörlerin belirlenmesine olanak tanırken, aynı zamanda gereksiz veri gürültüsünün ve hesaplama yükünün azaltılmasına katkı sağlar. Bu süreç, modelin genel doğruluğunu ve tahmin kabiliyetini artırmak için kritiktir ve yapılan özellik seçimi, modelin veri kümesi üzerindeki genelleştirme yeteneğini güçlendirmeye yöneliktir. Aşağıdaki Şekil 4.6.'da ise kullanılan modeller gösterilmiştir.

Models		
Sort by: Model Number		
1	Tree	Accuracy (Validation): 98.7%
Last change: Removed 4 features		
2	Binary GLM Logistic Regression	Accuracy (Validation): 95.0%
Last change: Removed 4 features		
3	Naive Bayes	Accuracy (Validation): 90.4%
Last change: Removed 4 features		
4	SVM	Accuracy (Validation): 99.3%
Last change: Removed 4 features		
5	KNN	Accuracy (Validation): 98.7%
Last change: Removed 4 features		

Şekil 4.6. Matlab programında verilerin eğitilmesi sürecinde kullanılan modeller.

Şekil 4.6.'da Matlab programında kullanılan modeller görülmektedir. Matlab 10 ana başlık altında toplam 34 model sunmaktadır. Bunlar ana başlıklar KA, ayırmacı (discriminant) analizi, lojistik regresyon sınıflandırıcıları, naive bayes sınıflandırıcıları, destek vektör makinesi, verimli bir şekilde eğitilmiş doğrusal sınıflandırıcılar (efficiently trained linear classifiers), en yakın komşu sınıflandırıcıları (nearest neighbor classifiers), çekirdek yaklaşım sınıflandırıcıları (kernel approximation classifiers), topluluk sınıflandırıcıları (ensemble classifiers) ve sinir ağı sınıflandırıcılarıdır (neural network classifiers). Bu çalışmada Matlab programında kullanılan ve KA çesidi olan, ince karar ağacı (fine tree) , lojistik regresyon sınıflandırıcılarından İLR (binary logistic regression), naive bayes sınıflandırıcılarından GNB, Gaussian SVM, en yakın komşu sınıflandırıcılarından K-En yakın komşu (cosine nearest neighbor) modelleri seçilmiştir. Seçilen bu beş model eğitilmiştir. Performans değerlendirme yöntemleri, bir ML modelinin performansını değerlendirmek için kullanılır. Sınıflama için en yaygın olarak kullanılan performans değerlendirme yöntemi Doğruluk (Validasyon)'dur. Doğruluk için Tablo 4.1'de gösterilen için karışıklık matrisi (TP, FP, FN, TN) değerlerine göre hesaplanmaktadır.

Tablo 4.1. İki sınıflı sınıflandırma için karışıklık matrisi

	Gerçek pozitif	Gerçek negatif
Tahmin Edilen Pozitif	TP	FP
Tahmin Edilen Negatif	FN	TN

Doğruluk model tarafından yapılan tüm tahminler içindeki doğru tahminlerin oranı ölçer ve Formül (4.1) ile hesaplanır.

$$Doğruluk = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.1)$$

Formül 4.1.'de geçen doğruluk, modelin doğru tahminlerinin (hem pozitif hem de negatif) toplam tahminlere oranı olarak hesaplanır. Ayrıca Şekil 4.6.'da doğruluk (validasyon) oranları görsel içerisinde verilmiştir. Buna göre aşağıdaki Tablo 4.2. oluşturulmuştur.

Tablo 4.2. Model doğruluk (validasyon) oranları.

Model Adı	Doğruluk (Validasyon) %
İnce karar ağacı	98,7
İkili lojistik regresyon	95,0
Gaussian Naive Bayes	90,4
Gaussian SVM	99,3
K-En yakın komşu	98,7

Yukarıdaki Tablo 4.2., modellerinin doğruluk oranlarını yüzdelik olarak sunmaktadır. Bu oranlar, her modelin validasyon aşamasında elde ettiği performansı gösterir. Gaussian SVM modelinin veri kümesindeki örüntüleri ayırt etmede son derece etkili olduğu ve yüksek oranda doğru tahminler yapabildiğini görülmektedir. GNB modeli ise en düşük bir doğruluk oranı ile sonuçlanmıştır, bu bağımsızlık varsayımının veri kümesi için tam olarak geçerli olmayabileceğini ifade eder. Aşağıdaki Tablo 4.3.'te ise modellerin doğrulama karışıklık matrisi (validation confusion matrix) verilmiştir.

Tablo 4.3. Modellerin eğitim sonrası karışıklık matrisleri.

Model no / Model Adı	Karışıklık Matrisi			
Model 1 İnce karar ağacı	Doğru sınıf	N	2401	19
		S1	16	347
			N	S1
			Tahmin sınıfı	
Model 2 İkili lojistik regresyon	Doğru sınıf	N	2360	60
		S1	78	285
			N	S1
			Tahmin sınıfı	

Tablo 4.3.(Devamı) Modellerin eğitim sonrası karışıklık matrisleri.


Model 3 Gaussian Naive Bayes	Doğru sınıf	N	2239	181
		S1	87	276
			N	S1
			Tahmin sınıfı	

Model 4 Gaussian SVM	Doğru sınıf	N	2412	8
		S1	12	351
			N	S1
			Tahmin sınıfı	

Model 5 K-En yakın komşu	Doğru sınıf	N	2413	7
		S1	29	334
			N	S1
			Tahmin sınıfı	

Tablo 4.3., çalışmada kullanılan modeller için eğitim sonrasında elde edilen karışıklık matrislerini sunmaktadır. Karışıklık matrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir tablodur ve modelin gerçek sınıflara göre tahminlerini gösterir. Bu matris, modelin tahminlerinin doğruluk metriğini hesaplamak için kullanılır. Bu karışıklık matrisleri, her bir modelin sınıfları ne kadar iyi ayırt ettiğini ve hatalı tahminlerin sıklığını göstermektedir. İlk model olan İnce KA, negatif sınıfta 2401 doğru negatif tahmin ve 19 yanlış pozitif tahmin yapmıştır; pozitif sınıfta ise 347 doğru pozitif ve 16 yanlış negatif tahmin gerçekleştirmiştir. İkinci model olan İkili Lojistik Regresyon, negatif sınıfta 2360 doğru negatif tahmin ve 60 yanlış pozitif tahmin ile pozitif sınıfta 285 doğru pozitif ve 78 yanlış negatif tahmin yapmıştır. Üçüncü model, GNB, negatif sınıfta 2239 doğru negatif ve 181 yanlış pozitif tahminle; pozitif sınıfta ise 276 doğru pozitif ve 87 yanlış negatif tahmin ile performans göstermiştir. Dördüncü model, Gaussian SVM, negatif sınıfta 2412 doğru negatif ve sadece 8 yanlış pozitif tahmin ile oldukça yüksek bir performans sergilemiş, pozitif sınıfta ise 351 doğru pozitif ve 12 yanlış negatif tahmin yapmıştır. Son olarak,

KEn Yakın Komşu modeli, negatif sınıfta 2413 doğru negatif ve 7 yanlış pozitif tahmin ile en iyi performansı gösterirken, pozitif sınıfta 334 doğru pozitif ve 29 yanlış negatif tahmin yaparak dikkate değer sonuçlar elde etmiştir. Bu sonuçlar, her bir modelin sınıflandırma kabiliyetini ve özellikle yanlış pozitif ile yanlış negatif tahmin oranlarını ortaya koymaktadır, bu da modellerin güçlü ve zayıf yönlerini değerlendirmede önemli bir göstergedir. Genel olarak, yanlış pozitif ve yanlış negatif değerlerin düşük olması, modelin verimliliğinin yüksek olduğunu gösterir. Gaussian SVM ve K-En Yakın Komşu modelleri, bu tabloda sunulan en düşük yanlış tahmin sayılarına sahip olarak öne çıkmaktadır. Aşağıdaki Şekil 4.7.'de ise kullanılan modellerin test sonrası durumları gösterilmiştir.



Models		
Sort by Model Number		
1 Tree	Accuracy (Test): 98.7%	Last change: Removed 4 features 5/9 features
2 Binary GLM Logistic Regression	Accuracy (Test): 95.3%	Last change: Removed 4 features 5/9 features
3 Naive Bayes	Accuracy (Test): 91.2%	Last change: Removed 4 features 5/9 features
4 SVM	Accuracy (Test): 99.3%	Last change: Removed 4 features 5/9 features
5 KNN	Accuracy (Test): 99.3%	Last change: Removed 4 features 5/9 features

Şekil 4.7. Test sonrası modeller.

Şekil 4.7.'de Matlab programında kullanılan modellerin test işlemi tamamlandıktan sonraki durumları görülmektedir. Görselde yer alan verilere göre aşağıdaki Tablo 4.4. hazırlanmıştır.

Tablo 4.4. Model test sonrası doğruluk oranları.

Model Adı	Doğruluk (Test) %
İnce karar ağacı	98,7
İkili lojistik regresyon	95,3
Gaussian Naive Bayes	91,2
Gaussian SVM	99,3
K-En yakın komşu	99,3

Tablo 4.4., çalışmada kullanılan modellerinin test aşamasında elde ettiği doğruluk oranlarını sunmaktadır. Bu oranlar, her bir modelin genel performansını ve test veri

kümesi üzerindeki tahmin kabiliyetini göstermektedir. Aşağıdaki Tablo 4.5.'te ise modellerin test karışıklık matrisi (test confusion matrix) verilmiştir.

Tablo 4.5. Modellerin test sonrası karışıklık matrisleri.

Model no / Model Adı		Karışıklık Matrisi	
Model 1 İnce karar ağacı	Doğru sınıf	N	601
	S1	5	85
		N	S1
		Tahmin sınıfı	
Model 2 İkili lojistik regresyon	Doğru sınıf	N	593
	S1	21	69
		N	S1
		Tahmin sınıfı	
Model 3 Gaussian Naive Bayes	Doğru sınıf	N	565
	S1	21	69
		N	S1
		Tahmin sınıfı	
Model 4 Gaussian SVM	Doğru sınıf	N	603
	S1	3	87
		N	S1
		Tahmin sınıfı	
Model 5 K-En yakın komşu	Doğru sınıf	N	603
	S1	3	87
		N	S1
		Tahmin sınıfı	

Tablo 4.5, çalışmada kullanılan modellerinin test aşamasındaki performanslarını karışıklık matrisleri aracılığıyla göstermektedir. Karışıklık matrisi, bir sınıflandırma modelinin hem doğru tahminlerini (doğru pozitifler ve doğru negatifler) hem de yanlış tahminlerini (yanlış pozitifler ve yanlış negatifler) detaylı bir şekilde sunar. Her modelin karışıklık matrisini ve performansını şu şekildedir.

Model 1, İnce Karar Ağacı: Bu model, negatif sınıfta, 601 doğru negatif tahmin ve 4 yanlış pozitif tahmin ile oldukça yüksek bir doğruluk göstermiş, pozitif sınıfta ise 85 doğru pozitif ve 5 yanlış negatif tahmin yapmıştır. Bu, İnce Karar Ağacı'nın yüksek genelleştirme kabiliyetine ve dengeli bir sınıflandırma performansına işaret eder.

Model 2, İkili Lojistik Regresyon: Bu model negatif sınıfta 593 doğru negatif ve 12 yanlış pozitif tahminle, pozitif sınıfta ise 69 doğru pozitif ve 21 yanlış negatif tahmin elde etmiştir. İkili lojistik regresyon, özellikle pozitif sınıftaki daha yüksek yanlış negatif tahminler nedeniyle bazı zorluklar yaşamış gibi görünmektedir.

Model 3, Gaussian Naive Bayes: Bu model, negatif sınıfta 565 doğru negatif ve 40 yanlış pozitif tahmin ile diğer modellere göre daha düşük bir performans sergilemiş, pozitif sınıfta ise 69 doğru pozitif ve 21 yanlış negatif tahmin yapmıştır. Bu modelin yüksek yanlış pozitif oranı, özelliklerin bağımsızlık varsayımının veri kümesi için ideal olmadığını gösterebilir.


Model 4, Gaussian SVM: Bu model, test edilen modeller arasında en yüksek performansı gösteren modellerden biridir. Negatif sınıfta 603 doğru negatif ve sadece 2 yanlış pozitif, pozitif sınıfta ise 87 doğru pozitif ve 3 yanlış negatif tahmin ile dikkat çekicidir. Bu, modelin sınıfları ayırt etme yeteneğinin oldukça yüksek olduğunu gösterir.

Model 5, K-En Yakın Komşu: Bu model de Gaussian SVM ile benzer sonuçlar göstermiş, negatif sınıfta 603 doğru negatif ve 2 yanlış pozitif, pozitif sınıfta ise 87 doğru pozitif ve 3 yanlış negatif tahmin elde etmiştir. Bu sonuçlar, modelin özellikle yüksek boyutlu verilerde iyi genelleştirme yapabildiğini ortaya koyar.

Özetle bu matrislerden, Model 4 Gaussian SVM ile Model 5 K-En yakın komşu, yüksek doğruluk oranlarına ve en iyi performansı değerlerine sahiptir. GNB modeli ise yanlış pozitif sayısının yüksekliği nedeniyle diğer modellere kıyasla daha düşük performans sergilemektedir. İkili lojistik regresyon ve İnce karar ağacı modelleri, sağlam ve güvenilir sonuçlar sunmakla birlikte, Gaussian SVM ve K-En Yakın Komşu


modellerinin sağladığı üst düzey doğruluk oranlarına kıyasla biraz daha fazla yanlış tahmin içermektedir. Bu sonuçlar, her bir modelin güçlü ve zayıf yönlerini ve potansiyel uygulama alanlarını değerlendirmede faydalı olacaktır. Aşağıdaki Tablo 4.6.'da kullanılan modellerin alıcı işletim karakteristik eğrisi ve eğri altında kalan alan analizleri yer almaktadır.

Tablo 4.6. İnce karar ağacı, İkili lojistik regresyon, Gaussian Naive Bayes, Gaussian SVM ve K-En yakın komşu algoritmalarının karşılaştırmalı alıcı işletim karakteristik eğrisi ve eğri altında kalan alan analizi grafikleri.




Tablo 4.6.(Devamı) İnce karar ağacı, İkili lojistik regresyon, Gaussian Naive Bayes, Gaussian SVM ve K-En yakın komşu algoritmalarının karşılaştırmalı alıcı işletim karakteristik eğrisi ve eğri altında kalan alan analizi grafikleri.


Model 3
Gaussian Naive Bayes



Model 4
Gaussian SVM



Model 5
K-En yakın komşu



Tablo 4.6.'da yer alan alıcı işletim karakteristik eğrisi, sınıflandırma modellerinin performansını değerlendirmede kullanılan önemli bir araçtır. Bu eğri, bir sınıflandırma modelinin çeşitli eşik değerlerindeki duyarlılık (hassasiyet veya gerçek pozitif oran) ve 1 - özgülük (yanlış pozitif oran) değerlerini grafik üzerinde gösterir. Alıcı işletim karakteristik eğrisi, modelin tüm olası eşiklerdeki performansını görsel olarak sunar ve modelin sınıfları ayırt etme kabiliyetini değerlendirmek için kullanılır.

Model 1, ince karar ağacı yöntemi kullanılarak elde edilen sonuçlar için eğri altında kalan alan değeri 0.9822 olarak hesaplanmıştır. Model 2, ikili lojistik regresyon analizi ile yapılarak 0.9794 eğri altında kalan alan değeri elde edilmiştir. Model 3'te, GNB algoritması kullanılarak yapılan tahminlerin eğri altında kalan alan değeri 0.9301 olarak belirlenmiştir. Model 4, Gaussian destek vektör makineleri (SVM) ile yapılan değerlendirmelerde eğri altında kalan alan değeri 0.9997 olarak ölçülmüş, bu da mükemmel bir sınıflandırma performansını işaret etmektedir. Son olarak, Model 5, kosinüs benzerliğine dayalı en yakın komşu yöntemi kullanılarak yapılan tahminler için eğri altında kalan alan değeri 0.9941 olarak tespit edilmiştir ve bu değer neredeyse mükemmel bir performansı göstermektedir.

Ek olarak, ML ve IoT teknolojileri kullanılarak elektrik panosu anormalliklerinin tespiti için geliştirilen bir çalışmada benzer sonuçlar elde edilmiştir. Bu çalışmada KA algoritması ile yapılan değerlendirmelerde eğri altında kalan alan değeri 0.97, GPC ile yapılan değerlendirmelerde 0.99, Gaussian SVM ile yapılan değerlendirmelerde 0.99 ve GNB algoritması ile yapılan tahminlerde 0.95 eğri altında kalan alan değeri ölçülmüştür (Pekşen, M. F., ve ark. 2024). Bu eğri altında kalan alan sonuçları, farklı istatistiksel modellerin performanslarının değerlendirilmesi ve görselleştirilmesi açısından önem taşımaktadır.



5. SONUÇLAR VE DEĞERLENDİRME

Bu çalışmada, elektrik pano yangınlarının tespiti amacıyla Matlab R2023b akademik versiyonu kullanılarak çeşitli ML modelleri üzerinden deney verilerinin işlenmesi ve performans değerlendirmesi gerçekleştirilmiştir. Denetimli öğrenme yöntemleri ve sınıflandırma tekniklerinin uygulanmasıyla elde edilen sonuçlar, model performanslarının doğruluk, yanlış pozitif ve yanlış negatif tahmin oranları açısından değerlendirilmiştir. Çalışma kapsamında 3478 satırdan oluşan veri kümesi kullanılmıştır. Her bir algoritma, 5-katlı çapraz doğrulama yöntemiyle değerlendirilmiştir. Böylelikle Matlab programı kullanılarak toplam 5 farklı model eğitimi ve testi yapılmıştır. Yapılan bu eğitimler ve testler sonucunda her algoritma için sonuçlar elde edilmiştir. Bunlar Tablo 5.1.'de ortak olarak verilmiştir.

Tablo 5.1. Modellerin doğruluk oranları (eğitim (validasyon) ve test)

Model Adı	Doğruluk (Validasyon) %	Doğruluk (Test) %
İnce karar ağacı	98,7	98,7
İkili lojistik regresyon (İLR)	95,0	95,3
Gaussian Naive Bayes (GNB)	90,4	91,2
Gaussian SVM	99,3	99,3
K-En yakın komşu (KNN)	98,7	99,3

Bu veriler, her bir modelin hem geliştirme (validasyon) aşamasında hem de bağımsız test veri kümesi üzerindeki performansını göstermektedir. İnce karar ağacı modeli hem validasyon hem de test sürecinde %98.7 gibi yüksek bir doğruluk oranı elde etmiştir. Bu tutarlılık, modelin genellemeye iyi bir şekilde adapte olduğunu ve aşırı öğrenme (overfitting) gibi sorunlardan etkilenmediğini gösterir. İkili lojistik regresyon modeli validasyon sürecindeki doğruluk oranı %95.0 iken, test sürecinde %95.3 olarak ölçülmüştür. İkili lojistik regresyon modelinin validasyon ve test aşamalarındaki benzer performansı, modelin kararlı ve güvenilir olduğunu işaret eder. GNB modeli, validasyon aşamasında %90.4 doğruluk oranı ile test edilmiş ve test sürecinde ise %91.2 doğruluk oranına ulaşmıştır. Bu artış, modelin test veri kümesindeki özelliklerle daha uyumlu hale geldiğini gösterebilir. Gaussian Destek Vektör Makinesi (SVM),

hem validasyon hem de test süreçlerinde %99.3 gibi dikkat çekici bir doğruluk oranı göstermiştir. Bu sonuçlar, modelin sınıflandırma sınırlarını etkili bir şekilde belirlediğini ve yüksek genelleştirme kabiliyetine sahip olduğunu ortaya koymaktadır. K-En yakın komşu modeli validasyon sürecinde %98.7 doğruluk oranı ile başarılı bir performans sergilemiş, test sürecinde ise doğruluk oranını %99.3'e yükseltmiştir. Kosinüs benzerliği kullanarak çalışan bu model, yüksek boyutlu verilerde özellikle başarılı olabilir. Bu veriler, farklı ML modellerinin hem validasyon hem de bağımsız test süreçlerindeki performanslarını göstermektedir. Her modelin karşılaştırmalı analizi, modellerin sınıflandırma kabiliyetlerinin güçlü ve zayıf yönlerini anlamak için değerli bilgiler sunmaktadır. Özellikle, Gaussian SVM ve K-En Yakın Komşu modellerinin yüksek doğruluk oranları, bu modellerin uygulama alanlarında özellikle tercih edilebileceğini göstermektedir. Bu analiz, hangi modelin belirli bir veri kümesi veya problem tanımı için en uygun olduğunu belirlemede yardımcı olabilir.

Sonuç olarak, bu analiz süreci, deney verilerini işleme ve ML modellerini değerlendirme konusunda güçlü bir metodoloji sunmaktadır. Yüksek doğruluk oranlarına sahip modeller, özellikle karmaşık veri yapılarını analiz etmede ve anlamlı bilgiler çıkarmada etkili olabilir. Bu çalışma, ileri analizler ve model geliştirmeler için sağlam bir temel oluşturmakta, ayrıca hangi modelin belirli bir veri kümesi veya problem tanımı için en uygun olduğunu belirlemede önemli ölçütler sağlamaktadır. Bu tür kapsamlı değerlendirmeler, ML uygulamalarının verimliliğini ve doğruluğunu artırmada kritik rol oynar.

IoT teknolojileri ve ML algoritmalarını kullanarak elektrik panolarında yangın riskini azaltmayı ve kestirimci bakım uygulamalarını geliştirmeyi hedefleyen çalışmada elde edilen bulgular, elektrik panolarının durumunu izleme ve erken uyarı sistemlerini destekleme potansiyeli taşımaktadır. Bu durum yangın risklerini minimize ederek elektrik panolarının güvenliğini artıracaktır.

KAYNAKLAR

- Abbassi, R., Arzaghi, E., Yazdi, M., Aryai, V., Garaniya, V., & Rahnamayiezekavat, P. (2022). Risk-based and predictive maintenance planning of engineering infrastructure: existing quantitative techniques and future directions. *Process Safety and Environmental Protection*.
- Abdel-Gawad, N. M., El Dein, A. Z., Mansour, D. E. A., Ahmed, H. M., Darwish, M. M. F., & Lehtonen, M. (2018). Multiple enhancement of PVC cable insulation using functionalized SiO₂ nanoparticles based nanocomposites. *Electric Power Systems Research*, 163, 612-625.
- Abdulqader, D. M., Abdulazeez, A. M., & Zeebaree, D. Q. (2020). Machine learning supervised algorithms of gene selection: A review. *Machine Learning*, 62(03), 233-244.
- Afrash, M. R., Mirbagheri, E., Mashoufi, M., & Kazemi-Arpanahi, H. (2023). Optimizing prognostic factors of five-year survival in gastric cancer patients using feature selection techniques with machine learning algorithms: a comparative study. *BMC Medical Informatics and Decision Making*, 23(1), 54.
- Agarwal, P., & Jha, G. (2021, April). Forest fire detection using classifiers and transfer learning. In 2021 IEEE International Conference on Robotics, Automation and Artificial Intelligence (RAAI) (pp. 29-33). IEEE.
- Alarifi, A. A. S., Phylaktou, H. N., & Andrews, G. E. (2016). What kills people in a fire? heat or smoke?. *9th SSC Proceedings*.
- Alassaf, M., & Qamar, A. M. (2022). Improving sentiment analysis of Arabic tweets by One-Way ANOVA. *Journal of King Saud University-Computer and Information Sciences*, 34(6), 2849-2859.
- Aljuaid, A., & Anwar, M. (2022). Survey of supervised learning for medical image processing. *SN Computer Science*, 3(4), 292.
- Alkhaleel, B. A. (2023). Machine learning applications in the resilience of interdependent critical infrastructure systems—A systematic literature review. *International Journal of Critical Infrastructure Protection*, 100646.
- Alom, M. Z., & Taha, T. M. (2017, June). Network intrusion detection for cyber security using unsupervised deep learning approaches. In 2017 IEEE national aerospace and electronics conference (NAECON) (pp. 63-69). IEEE.
- Althuwaynee, O. F., Aydda, A., Hwang, I. T., Lee, Y. K., Kim, S. W., Park, H. J., ... & Park, Y. (2021). Uncertainty reduction of unlabeled features in landslide inventory using machine learning t-SNE clustering and data mining apriori association rule algorithms. *Applied Sciences*, 11(2), 556.
- Anandaram, H., Nagalakshmi, M., Borda, R. F. C., Kiruthika, K., & Yogadinesh, S. (2023). Forest fire management using machine learning techniques. *Measurement: Sensors*, 25, 100659.

- Ananthi, J., Sengottaiyan, N., Anbukaruppusamy, S., Upreti, K., & Dubey, A. K. (2022). Forest fire prediction using IoT and deep learning. *International Journal of Advanced Technology and Engineering Exploration*, 9(87), 246-256.
- Andrew, A. M., Shakaff, A. Y. M., Zakaria, A., Gunasagaran, R., Kanagaraj, E., & Saad, S. M. (2018, December). Fuzzy K-nearest neighbour (FkNN) based early stage fire source classification in building. In 2018 IEEE Conference on Systems, Process and Control (ICSPC) (pp. 176-181). IEEE.
- Arabameri, A., Arora, A., Pal, S. C., Mitra, S., Saha, A., Nalivan, O. A., ... & Moayedi, H. (2021). K-fold and state-of-the-art metaheuristic machine learning approaches for groundwater potential modelling. *Water Resources Management*, 35, 1837-1869.
- Arabameri, A., Pradhan, B., & Lombardo, L. (2019). Comparative assessment using boosted regression trees, binary logistic regression, frequency ratio and numerical risk factor for gully erosion susceptibility modelling. *Catena*, 183, 104223.
- Arif, M., Alghamdi, K. K., Sahel, S. A., Alosaimi, S. O., Alsahft, M. E., Alharthi, M. A., & Arif, M. (2021). Role of machine learning algorithms in forest fire management: A literature review. *J. Robot. Autom*, 5, 212-226.
- Arora, A., Singh, V., Gourisaria, M. K., & Jena, A. K. (2022, July). Analyzing the Potability of Water using Machine Learning Algorithm. In 2022 Fifth International Conference on Computational Intelligence and Communication Technologies (CCICT) (pp. 250-256). IEEE.
- Asante-Okyere, S., Shen, C., & Osei, H. (2022). Enhanced machine learning tree classifiers for lithology identification using Bayesian optimization. *Applied Computing and Geosciences*, 16, 100100.
- Awad, M., Khanna, R., (2015). Support vector machines for classification. *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*, 39-66.
- Awadallah, M. A., Xu, T., Venkatesh, B., & Singh, B. N. (2015). On the effects of solar panels on distribution transformers. *IEEE Transactions on Power Delivery*, 31(3), 1176-1185.
- Aydın, N. (2023). Akıllı Şehirlerde Büyük Veri*. *Balkan & Near Eastern Journal of Social Sciences (BNEJSS)*, 9.
- Aydoğan, İ., & Akbal, H. (2023). Covid-19 Pandemi Döneminde Sağlık Hizmetlerinde 4.0 Uygulamalarına İlişkin Kullanımın Çok Kriterli Karar Verme İle Değerlendirilmesi. *Celal Bayar Üniversitesi Sağlık Bilimleri Enstitüsü Dergisi*, 10(4), 296-302.
- Ayvaz, B., Ilikçi, H., Gündoğdu, O. S., Bilgili, F., & Ergenç, A. F. (2023). Nesnelerin İnterneti Entegreli Çevrimiçi Yürüyüş Analiz Sistemi Tasarımı ve Uygulaması Internet of Things Integrated Online Gait Analysis System Design and Application.
- Ayvaz, S., & Alpay, K. (2021). Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time. *Expert Systems with Applications*, 173, 114598.

- Badamasi, Y. A. (2014, September). The working principle of an Arduino. In *2014 11th international conference on electronics, computer and computation (ICECCO)* (pp. 1-4). IEEE.
- Baek, J., Alhindi, T. J., Jeong, Y. S., Jeong, M. K., Seo, S., Kang, J., ... & Heo, Y. (2021). Real-time fire detection system based on dynamic time warping of multichannel sensor networks. *Fire Safety Journal*, 123, 103364.
- Baek, J., Park, M. H., Kim, T., & Youn, H. S. (2021). Modified power factor correction (PFC) control and printed circuit board (PCB) design for high-efficiency and high-power density on-board charger. *Energies*, 14(3), 605.
- Bagavathiappan, S., Lahiri, B. B., Saravanan, T., Philip, J., & Jayakumar, T. (2013). Infrared thermography for condition monitoring—A review. *Infrared Physics & Technology*, 60, 35-55.
- Bakdemir, S. A., Bozkurt, Y., & Salman, S. (2021). Eklemeli imalat yöntemlerinde metal tozu patlama riski ve önleme yöntemleri. *Journal of Innovative Engineering and Natural Science*, 1(1), 41-60.
- Bansal, M., Goyal, A., & Choudhary, A. (2022). A comparative analysis of K-nearest neighbor, genetic, support vector machine, decision tree, and long short term memory algorithms in machine learning. *Decision Analytics Journal*, 3, 100071.
- Barmpoutis, P., Papaioannou, P., Dimitropoulos, K., & Grammalidis, N. (2020). A review on early forest fire detection systems using optical remote sensing. *Sensors*, 20(22), 6442.
- Baron, G., & Stańczyk, U. (2021). Standard vs. non-standard cross-validation: evaluation of performance in a space with structured distribution of datapoints. *Procedia Computer Science*, 192, 1245-1254.
- Basha, S. M., & Rajput, D. S. (2019). Survey on evaluating the performance of machine learning algorithms: past contributions and future roadmap. In *Deep Learning and Parallel Computing Environment for Bioengineering Systems* (pp. 153-164). Academic Press.
- Begum, S., Chakraborty, D., & Sarkar, R. (2015, December). Data classification using feature selection and kNN machine learning approach. In *2015 International Conference on Computational Intelligence and Communication Networks (CICN)* (pp. 811-814). IEEE.
- Bepery, C., Baral, S., Khashkel, A., & Hossain, F. (2019). Advanced home automation system using Raspberry-Pi and Arduino. *International journal of computer science and engineering*, 8(2), 1-10.
- Bhavsar, H., & Ganatra, A. (2012). A comparative study of training algorithms for supervised machine learning. *International Journal of Soft Computing and Engineering (IJSCE)*, 2(4), 2231-2307.
- Bickerton, J. (2012). The fire triangle. *Loss Prevention Bulletin*, (226).
- Binaların Yangından Korunması Hakkında Yönetmelik, (2007). Resmî Gazete Sayı: 26735. Access address: <https://www.resmigazete.gov.tr/eskiler/2007/12/20071219-2.htm>.

- Bodur, A. (2020). A Research in Buildings in the Meaning of Fire Safety: The Case of Samsun. *Disaster Science and Engineering*, 6(2), 16-26.
- Bogetić, Ž., & Fedderke, J. W. (2006). Forecasting investment needs in South Africa's electricity and telecom sectors. *South African journal of economics*, 74(3), 557-574.
- Bolloor, A. J. (2015). *Arduino by example*. Packt Publishing Ltd.
- Bonaccorso, G. (2018). *Machine Learning Algorithms: Popular algorithms for data science and machine learning*. Packt Publishing Ltd.
- Boroń, S., Węgrzyński, W., Kubica, P., & Czarnecki, L. (2019). Numerical modelling of the fire extinguishing gas retention in small compartments. *Applied Sciences*, 9(4), 663.
- Brito, T., Pereira, A. I., Lima, J., & Valente, A. (2020). Wireless sensor network for ignitions detection: An IoT approach. *Electronics*, 9(6), 893.
- Bugata, P., & Drotar, P. (2020). On some aspects of minimum redundancy maximum relevance feature selection. *Science China Information Sciences*, 63(1), 112103.
- Cabral Júnior, J. B., & Lucena, R. L. (2020). Analysis of precipitation using Mann-Kendall and Kruskal-Wallis non-parametric tests. *Mercator (Fortaleza)*, 19, e19001.
- Cai, J., Luo, J., Wang, S., & Yang, S. (2018). Feature selection in machine learning: A new perspective. *Neurocomputing*, 300, 70-79.
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189-215.
- Chandra, M. A., & Bedi, S. S. (2021). Survey on SVM and their application in image classification. *International Journal of Information Technology*, 13, 1-11.
- Che, Y. (2023, January). Machine Learning Based Network Attacks Classification. In 2023 IEEE 3rd International Conference on Power, Electronics and Computer Applications (ICPECA) (pp. 1198-1203). IEEE.
- Chen, H., Hou, L., Zhang, G. K., & Moon, S. (2021). Development of BIM, IoT and AR/VR technologies for fire safety and upskilling. *Automation in Construction*, 125, 103631.
- Chen, S., Ren, J., Yan, Y., Sun, M., Hu, F., & Zhao, H. (2022). Multi-sourced sensing and support vector machine classification for effective detection of fire hazard in early stage. *Computers and Electrical Engineering*, 101, 108046.
- Chen, W. H., Uribe, M. C., Kwon, E. E., Lin, K. Y. A., Park, Y. K., Ding, L., & Saw, L. H. (2022). A comprehensive review of thermoelectric generation optimization by statistical approach: Taguchi method, analysis of variance (ANOVA), and response surface methodology (RSM). *Renewable and Sustainable Energy Reviews*, 169, 112917.
- Chen, X., Chen, X., Li, S., & Jiao, C. (2021). Copper metal-organic framework toward flame-retardant enhancement of thermoplastic polyurethane elastomer composites based on ammonium polyphosphate. *Polymers for Advanced Technologies*, 32(8), 2829-2842.

- Chen, X., Wang, W., Li, S., & Jiao, C. (2017). Fire safety improvement of para-aramid fiber in thermoplastic polyurethane elastomer. *Journal of hazardous materials*, 324, 789-796.
- Choudhary, R., & Gianey, H. K. (2017, December). Comprehensive review on supervised machine learning algorithms. In 2017 International Conference on Machine Learning and Data Science (MLDS) (pp. 37-43). IEEE.
- Chowdhury, M. Z. I., & Turin, T. C. (2020). Variable selection strategies and its importance in clinical prediction modelling. *Family medicine and community health*, 8(1).
- Chuvieco, E., Aguado, I., Salas, J., García, M., Yebra, M., & Oliva, P. (2020). Satellite remote sensing contributions to wildland fire science and management. *Current Forestry Reports*, 6, 81-96.
- Cleary, T. (2014). Performance of dual photoelectric/ionization smoke alarms in full-scale fire tests. *Fire Technology*, 50, 753-773.
- Cohen, Howard J., and Jeffrey S. Birkner. "Respiratory protection." *Clinics in Chest Medicine* 33, no. 4 (2012): 783-793.
- Cooley, J. J., Vickery, D., Avestruz, A. T., Clifford, Z., & Leeb, S. B. (2010, June). A retrofit 60 Hz current sensor for power monitoring at the circuit breaker panel. In *2010 IEEE 12th workshop on control and modeling for power electronics (COMPEL)* (pp. 1-7). IEEE.
- Crisci, C., Ghattas, B., & Perera, G. (2012). A review of supervised machine learning algorithms and their applications to ecological data. *Ecological Modelling*, 240, 113-122.
- Cui, F. (2020). Deployment and integration of smart sensors with IoT devices detecting fire disasters in huge forest environment. *Computer Communications*, 150, 818-827.
- Damaševičius, R., Bacanin, N., & Misra, S. (2023). From sensors to safety: Internet of Emergency Services (IoES) for emergency response and disaster management. *Journal of Sensor and Actuator Networks*, 12(3), 41.
- Dao, P. B., Barczewski, R., & Staszewski, W. J. Misalignment Fault Detection in Rotor-Shaft Systems Under Varying Load Conditions Based on Kruskal-Wallis Test and Tukey's Honestly Significant Difference Test. Available at SSRN 4757996.
- De Benedetti, M., Leonardi, F., Messina, F., Santoro, C., & Vasilakos, A. (2018). Anomaly detection and predictive maintenance for photovoltaic systems. *Neurocomputing*, 310, 59-68.
- Deepak, S., & Ameer, P. M. (2021). Automated categorization of brain tumor from mri using cnn features and svm. *Journal of Ambient Intelligence and Humanized Computing*, 12(8), 8357-8369.
- Demirel, F., & Konur, Z., (2006). Passive Fire Safety Precautions In Hotels According To The National And International Regulations And A Case Study. *JOURNAL OF THE FACULTY OF ENGINEERING AND ARCHITECTURE OF GAZI UNIVERSITY* , vol.2, 293-301.

- Dewitte, O., Daoudi, M., Bosco, C., & Van Den Eeckhaut, M. (2015). Predicting the susceptibility to gully initiation in data-poor regions. *Geomorphology*, 228, 101-115.
- Dharshini, S., Haneesh, T., Venugopal, E., & Sivakumar, P. (2022, December). Implementing BeagleBone Black as a Single Board Computer by Transferring E-mail using SMTP. In 2022 International Conference on Automation, Computing and Renewable Systems (ICACRS) (pp. 1184-1187). IEEE.
- Dike, H. U., Zhou, Y., Deveerasetty, K. K., & Wu, Q. (2018, October). Unsupervised learning based on artificial neural network: A review. In 2018 IEEE International Conference on Cyborg and Bionic Systems (CBS) (pp. 322-327). IEEE.
- Dileep, G. J. R. E. (2020). A survey on smart grid technologies and applications. *Renewable energy*, 146, 2589-2625.
- Doan, T., & Kalita, J. (2015, November). Selecting machine learning algorithms using regression models. In 2015 IEEE International Conference on Data Mining Workshop (ICDMW) (pp. 1498-1505). IEEE.
- Dogan, A., & Birant, D. (2021). Machine learning and data mining in manufacturing. *Expert Systems with Applications*, 166, 114060.
- Eckhardt, C. M., Madjarova, S. J., Williams, R. J., Ollivier, M., Karlsson, J., Pareek, A., & Nwachukwu, B. U. (2023). Unsupervised machine learning methods and emerging applications in healthcare. *Knee Surgery, Sports Traumatology, Arthroscopy*, 31(2), 376-381.
- Engelbrecht, A. P. (2007). *Computational intelligence: an introduction*. John Wiley & Sons.
- Ersöz, F., & Çınar, Y. (2021). Veri madenciliği ve makine öğrenimi yaklaşımlarının karşılaştırılması: Tekstil sektöründe bir uygulama. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 397-414.
- Fadhullah, W., Imran, N. I. N., Ismail, S. N. S., Jaafar, M. H., & Abdullah, H. (2022). Household solid waste management practices and perceptions among residents in the East Coast of Malaysia. *BMC public health*, 22, 1-20.
- Feng, W., Ma, C., Zhao, G., & Zhang, R. (2020, August). Fsrfr: an improved random forest for classification. In 2020 IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA) (pp. 173-178). IEEE.
- Ferdoush, S., & Li, X. (2014). Wireless sensor network system design using Raspberry Pi and Arduino for environmental monitoring applications. *Procedia Computer Science*, 34, 103-110.
- Flores Tapia, C. E., & Flores Cevallos, K. L. (2022). Kruskal-Wallis, Friedman and Mood nonparametric tests applied to business decision making. *Espirales Revista Multidisciplinaria de Investigación*, 6(43).
- Forestier, G., & Wemmert, C. (2016). Semi-supervised learning using multiple clusterings with limited labeled data. *Information Sciences*, 361, 48-65.
- Frunza, M. C. (2016). Support Vector Machines. In *Solving Modern Crime in Financial Markets* (pp. 205-215). Academic Press.

- Funda, A., ASLAY, F. Y., & Ceylan, Y. (2018). Arduino ile Uzaktan Switch Konfigürasyonu Yönetimi Tasarımı. *Erzincan University Journal of Science and Technology*, 11(3), 571-575.
- Gamble, C. E., & Schopf, M. (2010). Heat Transfer Fluid Leaks: Break the Fire Triangle. *Chemical Engineering*, 117(13), 26-33.
- Gammon, T., & Matthews, J. (2001, April). The application of a current-dependent arc model to arcing at a main distribution panel, a sub-panel and a branch circuit. In *Proceedings. IEEE SoutheastCon 2001 (Cat. No. 01CH37208)* (pp. 72-78). IEEE.
- Gao, W., Luo, X., Liu, Y., Zhao, Y., & Cui, Y. (2021). Development of an arduino-based integrated system for sensing of hydrogen peroxide. *Sensors and actuators reports*, 3, 100045.
- Gaur, A., Singh, A., Kumar, A., Kulkarni, K. S., Lala, S., Kapoor, K., ... & Mukhopadhyay, S. C. (2019). Fire sensing technologies: A review. *IEEE Sensors Journal*, 19(9), 3191-3202.
- Geetha, S., Abhishek, C. S., & Akshayanat, C. S. (2021). Machine vision based fire detection techniques: A survey. *Fire technology*, 57, 591-623.
- Ghosh, S., Dasgupta, A., & Swetapadma, A. (2019, February). A study on support vector machine based linear and non-linear pattern classification. In *2019 International Conference on Intelligent Sustainable Systems (ICISS)* (pp. 24-28). IEEE.
- Gips, B. (2022). Texture-based seafloor characterization using gaussian process classification. *IEEE Journal of Oceanic Engineering*, 47(4), 1058-1068.
- Glowacz, A. (2021). Fault diagnosis of electric impact drills using thermal imaging. *Measurement*, 171, 108815.
- Goswami, T. (2020). Machine learning behind classification tasks in various engineering and science domains. *Cognitive Informatics, Computer Modelling, and Cognitive Science*, 339–356.
- Gu, I. M., Yeon, Y. M., Ryu, D. S., & Kim, S. H. (2023). Optimization of Smoke-Detector Installation Location Based on Effect of Fan Equipment inside Distribution Panel on Fire Detection Performance. *Fire*, 6(2), 49.
- Gu, X., Deligianni, F., Han, J., Liu, X., Chen, W., Yang, G. Z., & Lo, B. (2023). Beyond supervised learning for pervasive healthcare. *IEEE Reviews in Biomedical Engineering*.
- Guillaumin, M., Verbeek, J., & Schmid, C. (2010, June). Multimodal semi-supervised learning for image classification. In *2010 IEEE Computer society conference on computer vision and pattern recognition* (pp. 902-909). IEEE.
- Gunduz, H. (2021). An efficient stock market prediction model using hybrid feature reduction method based on variational autoencoders and recursive feature elimination. *Financial innovation*, 7(1), 28.
- Guzmán-Fernández, M., Zambrano de la Torre, M., Ortega-Sigala, J., Guzmán-Valdivia, C., Galvan-Tejeda, J. I., Cruz-Domínguez, O., ... & Durán-Muñoz, H. A. (2021). Arduino: a Novel Solution to the Problem of High-Cost Experimental Equipment in Higher Education. *Experimental Techniques*, 1-13.

- Gündüz, M. Z., & Resul, D. A. Ş. (2018). Nesnelerin interneti: Gelişimi, bileşenleri ve uygulama alanları. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(2), 327-335.
- Günen, M. A. (2022). Nokta Bulutu Verisi Kullanılarak Elma Bahçesinden Meyve Tespiti. *El-Cezeri*, 9(1), 253-265.
- Güngör, M. (2008). Ki-kare testi üzerine. *Fırat Üniversitesi Doğu Araştırmaları Dergisi*, 7(1), 84-89.
- Haddadi, Y. R., & Mansouri, B. (2022, May). Ultrasound Medical Image Deconvolution Using L2 Regularization Method and Artificial Bee Colony Optimization Algorithm. In 2022 7th International Conference on Image and Signal Processing and their Applications (ISPA) (pp. 1-6). IEEE.
- Hagberg, E., Hagerman, D., Johansson, R., Hosseini, N., Liu, J., Björnsson, E., ... & Hjelmgren, O. (2022). Semi-supervised learning with natural language processing for right ventricle classification in echocardiography—a scalable approach. *Computers in Biology and Medicine*, 143, 105282.
- Han, S., Yang, F., Yang, G., Gao, B., Zhang, N., & Wang, D. (2020). Electrical equipment identification in infrared images based on ROI-selected CNN method. *Electric Power Systems Research*, 188, 106534.
- Harkat, H., Nascimento, J. M., Bernardino, A., & Ahmed, H. F. T. (2023). Fire images classification based on a handcraft approach. *Expert Systems with Applications*, 212, 118594.
- Hastie, T., Tibshirani, R., Friedman, J., Hastie, T., Tibshirani, R., & Friedman, J. (2009). Unsupervised learning. *The elements of statistical learning: Data mining, inference, and prediction*, 485-585.
- He, X., Feng, Y., Xu, F., Chen, F. F., & Yu, Y. (2022). Smart fire alarm systems for rapid early fire warning: Advances and challenges. *Chemical Engineering Journal*, 450, 137927.
- Herasymenko, P. (2021, March). Inexpensive High-Performance STM32-based Software PLL for Series-Resonant Inverters in Induction Heating Equipment. In 2021 12th International Symposium on Advanced Topics in Electrical Engineering (ATEE) (pp. 1-6). IEEE.
- Hernandez, S. M., & Bulut, E. (2020, August). Lightweight and standalone IoT based WiFi sensing for active repositioning and mobility. In 2020 IEEE 21st International Symposium on "A World of Wireless, Mobile and Multimedia Networks"(WoWMoM) (pp. 277-286). IEEE.
- Hernández-Garduño, E. (2020). Obesity is the comorbidity more strongly associated for Covid-19 in Mexico. A case-control study. *Obesity research & clinical practice*, 14(4), 375-379.
- Hoang, D., & Wiegatz, K. (2023). Machine learning methods in finance: Recent applications and prospects. *European Financial Management*, 29(5), 1657-1701.
- Hoq, M. T., Wang, J., & Taylor, N. (2021). Review of recent developments in distance protection of series capacitor compensated lines. *Electric Power Systems Research*, 190, 106831.

- Howell, D. C. (2011). Chi-square test: analysis of contingency tables. In *International encyclopedia of statistical science* (pp. 250-252). Springer, Berlin, Heidelberg.
- Hu, X., Che, Y., Lin, X., & Onori, S. (2020). Battery health prediction using fusion-based feature selection and machine learning. *IEEE Transactions on Transportation Electrification*, 7(2), 382-398.
- Huda, A. S. N., Taib, S., Ghazali, K., & Jadin, M. S. (2014). A new thermographic NDT for condition monitoring of electrical components using ANN with confidence level analysis. *ISA transactions*, 53(3), 717-724.
- Hurtuk, J., Chovanec, M., & Adam, N. (2017, October). The Arduino platform connected to education process. In *2017 IEEE 21st International Conference on Intelligent Engineering Systems (INES)* (pp. 000071-000076). IEEE.
- Ibarz, J., Tan, J., Finn, C., Kalakrishnan, M., Pastor, P., & Levine, S. (2021). How to train your robot with deep reinforcement learning: lessons we have learned. *The International Journal of Robotics Research*, 40(4-5), 698-721.
- Ingason, H. (2009). Design fire curves for tunnels. *Fire Safety Journal*, 44(2), 259-265.
- Ismail, N. H., & Mustapha, M. (2018). A review of thermoplastic elastomeric nanocomposites for high voltage insulation applications. *Polymer Engineering & Science*, 58(S1), E36-E63.
- Itajiba, J. A., Varnier, C. A. C., Cabral, S. H. L., Stefenon, S. F., Leithardt, V. R. Q., Ovejero, R. G., ... & Yow, K. C. (2021). Experimental comparison of preferential vs. common delta connections for the star-delta starting of induction motors. *Energies*, 14(5), 1318.
- İstanbul Büyükşehir Belediyesi İtfaiye Daire Başkanlığı (2020). İstatistikler 2020. http://itfaiye.ibb.gov.tr/img/_152291222020_.pdf
- İş Ekipmanlarının Kullanımında Sağlık ve Güvenlik Şartları Yönetmeliği, 2013
- Jadin, M. S., & Taib, S. (2012). Recent progress in diagnosing the reliability of electrical equipment by using infrared thermography. *Infrared Physics & Technology*, 55(4), 236-245.
- Jafari, M. J., Pouyakian, M., & Hanifi, S. M. (2020). Reliability evaluation of fire alarm systems using dynamic Bayesian networks and fuzzy fault tree analysis. *Journal of Loss Prevention in the Process Industries*, 67, 104229.
- Jahromi, A. H., & Taheri, M. (2017, October). A non-parametric mixture of Gaussian naive Bayes classifiers based on local independent features. In *2017 Artificial intelligence and signal processing conference (AISP)* (pp. 209-212). IEEE.
- Javaid, M., Haleem, A., Rab, S., Singh, R. P., & Suman, R. (2021). Sensors for daily life: A review. *Sensors International*, 2, 100121.
- Jeon, H., & Oh, S. (2020). Hybrid-recursive feature elimination for efficient feature selection. *Applied Sciences*, 10(9), 3211.
- Jiang, G., & Wang, W. (2017). Error estimation based on variance analysis of k-fold cross-validation. *Pattern Recognition*, 69, 94-106.
- Jiang, T., Gradus, J. L., & Rosellini, A. J. (2020). Supervised machine learning: a brief primer. *Behavior Therapy*, 51(5), 675-687.

- Jindarat, S., & Wuttidittachotti, P. (2015, April). Smart farm monitoring using Raspberry Pi and Arduino. In 2015 International Conference on Computer, Communications, and Control Technology (I4CT) (pp. 284-288). IEEE.
- Johnston, S. J., & Cox, S. J. (2017). The raspberry Pi: A technology disrupter, and the enabler of dreams. *Electronics*, 6(3), 51.
- Jolles, J. W. (2021). Broad-scale applications of the Raspberry Pi: A review and guide for biologists. *Methods in Ecology and Evolution*, 12(9), 1562-1579.
- Jović, A., Brkić, K., & Bogunović, N. (2015, May). A review of feature selection methods with applications. In *2015 38th international convention on information and communication technology, electronics and microelectronics (MIPRO)* (pp. 1200-1205). Ieee.
- Juarez-Lopez, J. M., Franco, J. A., Hernandez-Escobedo, Q., Muñoz-Rodríguez, D., & Perea-Moreno, A. J. (2023). Analysis of a Novel Proposal Using Temperature and Efficiency to Prevent Fires in Photovoltaic Energy Systems. *Fire*, 6(5), 196.
- Junwei, D., Weiping, L., Cui, T., & Xida, Y. (2020, May). Fire detector based on serial FBG temperature sensors optical cabling. In *Journal of Physics: Conference Series* (Vol. 1550, No. 4, p. 042054). IOP Publishing.
- Kadhim, A. I. (2019). Survey on supervised machine learning techniques for automatic text classification. *Artificial Intelligence Review*, 52(1), 273-292.
- Kamel, H., Abdulah, D., & Al-Tuwaijari, J. M. (2019, June). Cancer classification using gaussian naive bayes algorithm. In 2019 international engineering conference (IEC) (pp. 165-170). IEEE.
- Kanmaz, A., Örenbaş, H., & Şahin, S. (2018, May). Android based PLC data monitoring interface with industrial data communication port. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- KARA, İ. B. (2017). Giresun İli Yangın İstatistiklerinin İncelenmesi (2011-2016). *Karadeniz Fen Bilimleri Dergisi*, 7(2), 96-105.
- Karaman, S. (2023). *Akıllı şehirlerde nesnelerin interneti teknolojisinin önemi: Dünya'dan ve Türkiye'den örnek uygulamalar* (Master's thesis, Necmettin Erbakan Üniversitesi Sosyal Bilimler Enstitüsü).
- Karami, G., Giuseppe Orlando, M., Delli Pizzi, A., Caulo, M., & Del Gratta, C. (2021). Predicting overall survival time in glioblastoma patients using gradient boosting machines algorithm and recursive feature elimination technique. *Cancers*, 13(19), 4976.
- Kaur, S., Kaur, J., & Sharma, A. (2023). Predicting the performance of radio over free space optics system using machine learning techniques. *Optik*, 281, 170798.
- Kaya, M. S., & Kenan, İ. N. C. E. (2023). Nesnelerin İnternetinde Dallanmasız Programlama Tekniklerinin Uygulanması. *Computer Science*, (IDAP-2023), 83-89.
- Kayhan, B. M., & Yildiz, G. (2023). Reinforcement learning applications to machine scheduling problems: a comprehensive literature review. *Journal of Intelligent Manufacturing*, 34(3), 905-929.

- Khan, F., Xu, Z., Sun, J., Khan, F. M., Ahmed, A., & Zhao, Y. (2022). Recent advances in sensors for fire detection. *Sensors*, 22(9), 3310.
- Kılıç, S. (2016). Ki-kare Testi. *Journal of Mood Disorders*, 6(3).
- Kiliçkiran, H. C., Şengör, İ., Akdemir, H., Kekezoğlu, B., Erdiñç, O., & Paterakis, N. G. (2018). Power system protection with digital overcurrent relays: A review of non-standard characteristics. *Electric Power Systems Research*, 164, 89-102.
- Kiran, B. R., Sobh, I., Talpaert, V., Mannion, P., Al Sallab, A. A., Yogamani, S., & Pérez, P. (2021). Deep reinforcement learning for autonomous driving: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 23(6), 4909-4926.
- Kohse-Höinghaus, K. (2023). Combustion, Chemistry, and Carbon Neutrality. *Chemical Reviews*, 123(8), 5139-5219.
- Kondaveeti, H. K., Kumaravelu, N. K., Vanambathina, S. D., Mathe, S. E., & Vappangi, S. (2021). A systematic literature review on prototyping with Arduino: Applications, challenges, advantages, and limitations. *Computer Science Review*, 40, 100364.
- Korkmaz, E., (2016). Defining Fire Safety Design in Architectural Education. *MEGARON* , vol.11, no.2, 217-229.
- Köçer, M. S., & Aslan, R. (2023). Gönüllü Arama Kurtarma Ekiplerinin Orman Yangınlarındaki Tahliye Deneyimleri: 2021 Akdeniz Orman Yangınları. *Afet ve Risk Dergisi*, 6(3), 829-851.
- Krüger, S., Despinasse, M. C., Raspe, T., Nörthemann, K., & Moritz, W. (2017). Early fire detection: Are hydrogen sensors able to detect pyrolysis of house hold materials?. *Fire Safety Journal*, 91, 1059-1067.
- Kumar, N., & Kumar, A. (2020, July). Australian bushfire detection using machine learning and neural networks. In 2020 7th International Conference on Smart Structures and Systems (ICSSS) (pp. 1-7). IEEE.
- Kumar, P., & Kumar, S. V. (2023, August). DDoS Attack Prediction System Using Machine Learning Algorithms. In International Conference on ICT for Sustainable Development (pp. 347-357). Singapore: Springer Nature Singapore.
- Kushnir, A., & Kopchak, B. (2021, May). Development of Multiband Flame Detector with Fuzzy Correction Block. In 2021 IEEE XVIIth International Conference on the Perspective Technologies and Methods in MEMS Design (MEMSTECH) (pp. 58-63). IEEE.
- Lakshmanaprabu, S. K., Shankar, K., Ilayaraja, M., Nasir, A. W., Vijayakumar, V., & Chilamkurti, N. (2019). Random forest for big data classification in the internet of things using optimal features. *International journal of machine learning and cybernetics*, 10(10), 2609-2618.
- Lei, X., Mohamad, U. H., Sarlan, A., Shutaywi, M., Daradkeh, Y. I., & Mohammed, H. O. (2022). Development of an intelligent information system for financial analysis depend on supervised machine learning algorithms. *Information Processing & Management*, 59(5), 103036.

- Li, W., Chai, Y., Khan, F., Jan, S. R. U., Verma, S., Menon, V. G., ... & Li, X. (2021). A comprehensive survey on machine learning-based big data analytics for IoT-enabled smart healthcare system. *Mobile networks and applications*, 26, 234-252.
- Li, Y., Qi, L., Liu, Y., Qiao, J., Wang, M., Liu, X., & Li, S. (2022). Recent advances in halogen-free flame retardants for polyolefin cable sheath materials. *Polymers*, 14(14), 2876.
- Li, Y., Sun, Y., Gao, Y., Sun, J., Lyu, H. F., Yu, T., ... & Wang, Y. (2022). Analysis of overload induced arc formation and beads characteristics in a residential electrical cable. *Fire Safety Journal*, 131, 103626.
- Li, Y., Yu, L., Zheng, C., Ma, Z., Yang, S., Song, F., ... & Tittel, F. K. (2022). Development and field deployment of a mid-infrared CO and CO₂ dual-gas sensor system for early fire detection and location. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 270, 120834.
- Lian, W., Nie, G., Jia, B., Shi, D., Fan, Q., & Liang, Y. (2020). An intrusion detection method based on decision tree-recursive feature elimination in ensemble learning. *Mathematical Problems in Engineering*, 2020, 1-15.
- Liberman, M. A. (2010). *Introduction to physics and chemistry of combustion: explosion, flame, detonation*. Springer Science & Business Media.
- Liu, H., Zhou, M., & Liu, Q. (2019). An embedded feature selection method for imbalanced data classification. *IEEE/CAA Journal of Automatica Sinica*, 6(3), 703-715.
- Liu, J., Li, J., & Fan, C. (2020). A bibliometric study of pool fire related publications. *Journal of Loss Prevention in the Process Industries*, 63, 104030.
- Lv, L. Y., Cao, C. F., Qu, Y. X., Zhang, G. D., Zhao, L., Cao, K., ... & Tang, L. C. (2022). Smart fire-warning materials and sensors: Design principle, performances, and applications. *Materials Science and Engineering: R: Reports*, 150, 100690.
- MacLeod, J., Tan, S., & Moinuddin, K. (2020). Reliability of fire (point) detection system in office buildings in Australia—A fault tree analysis. *Fire safety journal*, 115, 103150.
- Mahadevkar, S. V., Khemani, B., Patil, S., Kotecha, K., Vora, D. R., Abraham, A., & Gabralla, L. A. (2022). A review on machine learning styles in computer vision—Techniques and future directions. *Ieee Access*, 10, 107293-107329.
- Mahbub, M., Hossain, M. M., & Gazi, M. S. A. (2021). Cloud-Enabled IoT-based embedded system and software for intelligent indoor lighting, ventilation, early stage fire detection and prevention. *Computer Networks*, 184, 107673.
- Malaysia Fire and Rescue Department (2021). Annual report 2021. https://www.bomba.gov.my/wp-content/uploads/2023/01/Laporan-Tahun-2021_compressed.pdf
- Maldonado, S., López, J., & Iturriaga, A. (2022). Out-of-time cross-validation strategies for classification in the presence of dataset shift. *Applied Intelligence*, 52(5), 5770-5783.

- Mandadi, G. K., Asmatulu, R., Khan, W. S., & Asmatulu, E. (2020). Fast and affordable recycling approach to electronic waste above the melting point using induction heat combined with centrifugal forces. *Asia-Pacific Journal of Chemical Engineering*, 15(4), e2483.
- Mappuji, A., Effendy, N., Mustaghfirin, M., Sondok, F., Yuniar, R. P., & Pangesti, S. P. (2016, October). Study of Raspberry Pi 2 quad-core Cortex-A7 CPU cluster as a mini supercomputer. In 2016 8th International Conference on Information Technology and Electrical Engineering (ICITEE) (pp. 1-4). IEEE.
- Martin, S., Fernandez-Pacheco, A., Ruipérez-Valiente, J. A., Carro, G., & Castro, M. (2021). Remote Experimentation Through Arduino-Based Remote Laboratories. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, 16(2), 180-186.
- May, R. J., Maier, H. R., & Dandy, G. C. (2010). Data splitting for artificial neural networks using SOM-based stratified sampling. *Neural Networks*, 23(2), 283-294.
- McManus, S., & Cook, M. (2021). *Raspberry Pi for dummies*. John Wiley & Sons.
- McRoberts, M. (2013). *Beginning arduino*. Apress.
- Mehmood, B., Akbar, M., & Ullah, R. (2020). Accelerated aging effect on high temperature vulcanized silicone rubber composites under DC voltage with controlled environmental conditions. *Engineering Failure Analysis*, 118, 104870.
- Memane, S. E., & Kulkarni, V. S. (2015). A review on flame and smoke detection techniques in video's. *Int. J. Adv. Res. Electrical, Electronics Instrumen. Eng*, 4(2), 885-889.
- Metwally, I. A. (2012). The evolution of medium voltage power cables. *IEEE Potentials*, 31(3), 20-25.
- Miao, J., & Niu, L. (2016). A survey on feature selection. *Procedia Computer Science*, 91, 919-926.
- Mittal, S. (2019). A Survey on optimized implementation of deep learning models on the NVIDIA Jetson platform. *Journal of Systems Architecture*, 97, 428-442.
- Mo, M., Wang, D., Li, B., Hong, D., & King, I. (2010, July). Exploit of online social networks with semi-supervised learning. In The 2010 International Joint Conference on Neural Networks (IJCNN) (pp. 1-8). IEEE.
- Mobley, R. K. (2011). *Maintenance fundamentals*. Elsevier.
- Molina-Cantero, A. J., Castro-García, J. A., Lebrato-Vázquez, C., Gómez-González, I. M., & Merino-Monge, M. (2018). Real-time processing library for open-source hardware biomedical sensors. *Sensors*, 18(4), 1033.
- More, A. S., & Rana, D. P. (2017, October). Review of random forest classification techniques to resolve data imbalance. In 2017 1st International conference on intelligent systems and information management (ICISIM) (pp. 72-78). IEEE.
- Morélot, S., Garrigou, A., Dedieu, J., & N'Kaoua, B. (2021). Virtual reality for fire safety training: Influence of immersion and sense of presence on conceptual and procedural acquisition. *Computers & Education*, 166, 104145.

- Mróz, K., Hager, I., & Korniejenko, K. (2016). Material solutions for passive fire protection of buildings and structures and their performances testing. *Procedia Engineering*, 151, 284-291.
- Mudaliar, M. D., & Sivakumar, N. (2020). IoT based real time energy monitoring system using Raspberry Pi. *Internet of Things*, 12, 100292.
- Murty, K. A. (1975). *Introduction to combustion phenomena* (Vol. 2). CRC Press.
- Nagarhalli, T. P., Vaze, V., & Rana, N. K. (2021, February). Impact of machine learning in natural language processing: A review. In 2021 third international conference on intelligent communication technologies and virtual mobile networks (ICICV) (pp. 1529-1534). IEEE.
- Naiem, S., Khedr, A. E., Marie, M., & Idrees, A. M. (2023). Enhancing the Efficiency of Gaussian Naïve Bayes Machine Learning Classifier in the Detection of DDOS in Cloud Computing. *IEEE Access*.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons*. b, 4, 51-62.
- Neethirajan, S. (2020). The role of sensors, big data and machine learning in modern animal farming. *Sensing and Bio-Sensing Research*, 29, 100367.
- Nematzadeh, Z., Ibrahim, R., & Selamat, A. (2015, May). Comparative studies on breast cancer classifications with k-fold cross validations using machine learning techniques. In 2015 10th Asian control conference (ASCC) (pp. 1-6). IEEE.
- NFPA 70B, Recommended Practice for Electrical Equipment Maintenance, 2016 edition, Section 11, Annex K, Annex L <https://link.nfpa.org/free-access/publications/70B/2023>
- Nižetić, S., Šolić, P., Gonzalez-De, D. L. D. I., & Patrono, L. (2020). Internet of Things (IoT): Opportunities, issues and challenges towards a smart and sustainable future. *Journal of cleaner production*, 274, 122877.
- Nti, I. K., Nyarko-Boateng, O., & Aning, J. (2021). Performance of machine learning algorithms with different K values in K-fold cross-validation. *International Journal of Information Technology and Computer Science*, 13(6), 61-71.
- O'Connor, C. D., Calkin, D. E., & Thompson, M. P. (2017). An empirical machine learning method for predicting potential fire control locations for pre-fire planning and operational fire management. *International journal of wildland fire*, 26(7), 587-597.
- Occupational Safety and Health Administration. (29). CFR 1910.134. *Respiratory Protection*.
- Occupational Safety and Health Administration. OSHA 3644-04 (2013). Firefighting Precautions at Facilities with Combustible Dust.
- O'driscoll, E., & O'donnell, G. E. (2013). Industrial power and energy metering—a state-of-the-art review. *Journal of Cleaner Production*, 41, 53-64.
- Ong, N. A. F. M. N., Sadiq, M. A., Said, M. S. M., Jomaas, G., Tohir, M. Z. M., & Kristensen, J. S. (2022). Fault tree analysis of fires on rooftops with photovoltaic systems. *Journal of Building Engineering*, 46, 103752.

- Ouache, R., Bakhtavar, E., Hu, G., Hewage, K., & Sadiq, R. (2022). Evidential reasoning and machine learning-based framework for assessment and prediction of human error factors-induced fire incidents. *Journal of Building Engineering*, 49, 104000.
- Parady, G., Ory, D., & Walker, J. (2021). The overreliance on statistical goodness-of-fit and under-reliance on model validation in discrete choice models: A review of validation practices in the transportation academic literature. *Journal of Choice Modelling*, 38, 100257.
- PEKŞEN, M. F., UYAROĞLU, Y., & SOYHAN, H. S. (2020). İstanbul, Ankara ve Sakarya İllerinin 2018 Yılı İtfaiye Olaylarının Karşılaştırılması. *Uluslararası Yakıtlar Yanma Ve Yangın Dergisi*, (8), 1-19.
- Pekşen, M. F., Yurtsever, U., & Uyaroglu, Y. (2024). Enhancing electrical panel anomaly detection for predictive maintenance with machine learning and IoT. *Alexandria Engineering Journal*, 96, 112-123.
- Pham, B. T., Jaafari, A., Avand, M., Al-Ansari, N., Dinh Du, T., Yen, H. P. H., ... & Tuyen, T. T. (2020). Performance evaluation of machine learning methods for forest fire modeling and prediction. *Symmetry*, 12(6), 1022.
- Pham, B. T., Van Dao, D., Acharya, T. D., Van Phong, T., Costache, R., Van Le, H., ... & Prakash, I. (2021). Performance assessment of artificial neural network using chi-square and backward elimination feature selection methods for landslide susceptibility analysis. *Environmental Earth Sciences*, 80, 1-13.
- Pise, N. N., & Kulkarni, P. (2008, December). A survey of semi-supervised learning methods. In 2008 International conference on computational intelligence and security (Vol. 2, pp. 30-34). IEEE.
- Pittman, W., & McNay, J. (2023). Applying intelligent visual flame detection in military aircraft hangars.
- Princy, S. E., & Nigel, K. G. J. (2015, November). Implementation of cloud server for real time data storage using Raspberry Pi. In 2015 online international conference on green engineering and technologies (IC-GET) (pp. 1-4). IEEE.
- Purdum, J., & Purdum, J. (2015). *Arduino c. Beginning C for Arduino: Learn C Programming for the Arduino*, 23-44.
- Qin, S. J., & Chiang, L. H. (2019). Advances and opportunities in machine learning for process data analytics. *Computers & Chemical Engineering*, 126, 465-473.
- Qin, Z., Li, W., & Xiong, X. (2011). Estimating wind speed probability distribution using kernel density method. *Electric Power Systems Research*, 81(12), 2139-2146.
- Quttineh, N. H., Olsson, P. M., Larsson, T., & Lindell, H. (2022). An optimization approach to the design of outdoor thermal fire detection systems. *Fire safety journal*, 129, 103548.
- Radovic, M., Ghalwash, M., Filipovic, N., & Obradovic, Z. (2017). Minimum redundancy maximum relevance feature selection approach for temporal gene expression data. *BMC bioinformatics*, 18, 1-14.

- Ramana Karumanchi, V., Raju, S. H., Kavitha, S., Lalitha, V. L., & Krishna, S. V. (2021, March). Fully Smart fire detection and prevention in the authorized forests. In *2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS)* (pp. 573-579). IEEE.
- Ramasubramanian, S., Muthukumaraswamy, S. A., & Sasikala, A. (2020, May). Fire detection using artificial intelligence for fire-fighting robots. In *2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS)* (pp. 180-185). IEEE.
- Ramo, R., & Chuvieco, E. (2017). Developing a random forest algorithm for MODIS global burned area classification. *Remote Sensing*, 9(11), 1193.
- Rathod, T., Patil, V., Harikrishnan, R., & Shahane, P. (2023). Multipurpose deep learning-powered UAV for forest fire prevention and emergency response. *HardwareX*, 16, e00479.
- Ratner, B. (2010). Variable selection methods in regression: Ignorable problem, outing notable solution. *Journal of Targeting, Measurement and Analysis for Marketing*, 18, 65-75.
- Raza, M., Chen, Y., Trapp, J., Sun, H., Huang, X., & Ren, W. (2023). Smoldering peat fire detection by time-resolved measurements of transient CO₂ and CH₄ emissions using a novel dual-gas optical sensor. *Fuel*, 334, 126750.
- Razmjoo, A., Xanthopoulos, P., & Zheng, Q. P. (2017). Online feature importance ranking based on sensitivity analysis. *Expert Systems with Applications*, 85, 397-406.
- Rezaee, N., Zanjirchi, S. M., Jalilian, N., & Bamakan, S. M. H. (2023). Internet of things empowering Operations Management; A systematic review based on bibliometric and content analysis. *Telematics and Informatics Reports*, 100096.
- Rezapour, M., Molan, A. M., & Ksaibati, K. (2020). Analyzing injury severity of motorcycle at-fault crashes using machine learning techniques, decision tree and logistic regression models. *International journal of transportation science and technology*, 9(2), 89-99.
- Richhariya, B., Tanveer, M., Rashid, A. H., & Alzheimer's Disease Neuroimaging Initiative. (2020). Diagnosis of Alzheimer's disease using universum support vector machine based recursive feature elimination (USVM-RFE). *Biomedical Signal Processing and Control*, 59, 101903.
- Roque, G., & Padilla, V. S. (2020). LPWAN based IoT surveillance system for outdoor fire detection. *IEEE Access*, 8, 114900-114909.
- Rtayli, N., & Enneya, N. (2020). Enhanced credit card fraud detection based on SVM-recursive feature elimination and hyper-parameters optimization. *Journal of Information Security and Applications*, 55, 102596.
- Sadi, M., Zhang, Y., Xie, W. F., & Hossain, F. A. (2021, June). Forest fire detection and localization using thermal and visual cameras. In *2021 International Conference on Unmanned Aircraft Systems (ICUAS)* (pp. 744-749). IEEE.
- Saeed, F., Paul, A., Karthigaikumar, P., & Nayyar, A. (2020). Convolutional neural network based early fire detection. *Multimedia Tools and Applications*, 79(13), 9083-9099.

- Sainz-Raso, J., Martin, S., Diaz, G., & Castro, M. (2019). Security vulnerabilities in raspberry pi—analysis of the system weaknesses. *IEEE Consumer Electronics Magazine*, 8(6), 47-52.
- Sánchez-Hernández, G., Chiclana, F., Agell, N., & Aguado, J. C. (2013). Ranking and selection of unsupervised learning marketing segmentation. *Knowledge-based systems*, 44, 20-33.
- Santiago Egea, Albert Rego Manez, Belen Carro, Antonio Sanchez-Esgunevillas and Jaime Lloret, "Intelligent IoT Traffic Classification Using Novel Search Strategy for Fast-Based-Correlation Feature Selection in Industrial Environment", *IEEE Internet of Things Journal*, vol. 5, no. 3, JUNE 2018.
- Sărăcin, C. G., & Paraipan, D. (2021). Software programs used in designing of low voltage electrical distribution panels. *Revista Romana de Inginerie Civila*, 12(4), 439-446.
- Sarailidis, G., Wagener, T., & Pianosi, F. (2023). Integrating scientific knowledge into machine learning using interactive decision trees. *Computers & Geosciences*, 170, 105248.
- Scheffer, C., & Girdhar, P. (2004). *Practical machinery vibration analysis and predictive maintenance*. Elsevier.
- Schmarje, L., Santarossa, M., Schröder, S. M., & Koch, R. (2021). A survey on semi-, self-and unsupervised learning for image classification. *IEEE Access*, 9, 82146-82168.
- Seefried, J., Gläbel, T., Zürn, M., & Franke, J. (2017, December). Evaluation of monitoring approaches for the ultrasonic crimping process of tubular cable lugs. In *2017 7th International Electric Drives Production Conference (EDPC)* (pp. 1-6). IEEE.
- Sen, K., & Verma, B. (2023, May). Heart Disease Prediction Using a Soft Voting Ensemble of Gradient Boosting Models, RandomForest, and Gaussian Naive Bayes. In *2023 4th International Conference for Emerging Technology (INCET)* (pp. 1-7). IEEE.
- Sert, S. A. (2023). Sınır Güvenliği için Etkin ve Güvenli Bir Çözüm—Blokzincir Tabanlı Nesnelerin İnterneti. *Savunma Bilimleri Dergisi*, 2(43), 493-517.
- Shafiee, S., Lied, L. M., Burud, I., Dieseth, J. A., Alsheikh, M., & Lillemo, M. (2021). Sequential forward selection and support vector regression in comparison to LASSO regression for spring wheat yield prediction based on UAV imagery. *Computers and Electronics in Agriculture*, 183, 106036.
- Shafizadeh-Moghadam, H. (2021). Fully component selection: An efficient combination of feature selection and principal component analysis to increase model performance. *Expert Systems with Applications*, 186, 115678.
- Shah, K., Patel, H., Sanghvi, D., & Shah, M. (2020). A comparative analysis of logistic regression, random forest and KNN models for the text classification. *Augmented Human Research*, 5(1), 12.
- Shan, Y., Zheng, B., Chen, L., Chen, L., & Chen, D. (2020). A reinforcement learning-based adaptive path tracking approach for autonomous driving. *IEEE Transactions on Vehicular Technology*, 69(10), 10581-10595.

- Sharma, A., Singh, P. K., & Kumar, Y. (2020). An integrated fire detection system using IoT and image processing technique for smart cities. *Sustainable Cities and Society*, 61, 102332.
- Sharma, N. V., & Yadav, N. S. (2021). An optimal intrusion detection system using recursive feature elimination and ensemble of classifiers. *Microprocessors and Microsystems*, 85, 104293.
- Sharma, R., Rani, S., & Memon, I. (2020). A smart approach for fire prediction under uncertain conditions using machine learning. *Multimedia Tools and Applications*, 79, 28155-28168.
- Sharpe, C., Wiest, T., Wang, P., & Seepersad, C. C. (2019). A comparative evaluation of supervised machine learning classification techniques for engineering design applications. *Journal of Mechanical Design*, 141(12), 121404.
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325.
- Shin, D. J., & Kim, J. J. (2022). A deep learning framework performance evaluation to use yolo in nvidia jetson platform. *Applied Sciences*, 12(8), 3734.
- Shrivastava, A., Chakkaravarthy, M., & Shah, M. A. (2023). A new machine learning method for predicting systolic and diastolic blood pressure using clinical characteristics. *Healthcare Analytics*, 4, 100219.
- Singh, G., Kumar, T. A., & Naikan, V. N. A. (2016, March). Fault diagnosis of induction motor cooling system using infrared thermography. In *2016 IEEE 6th international conference on power systems (ICPS)* (pp. 1-4). IEEE.
- Sinoplu, M., & Ceyhan, E. B. (2023). Akıllı Binalarda Yapay Zekâ Destekli Enerji Yönetimi: Bir İnceleme. *Uluslararası Batı Karadeniz Mühendislik ve Fen Bilimleri Dergisi*, 5(1), 39-63.
- Smiti, A. (2020). When machine learning meets medical world: Current status and future challenges. *Computer Science Review*, 37, 100280.
- Solórzano, A., Eichmann, J., Fernández, L., Ziems, B., Jiménez-Soto, J. M., Marco, S., & Fonollosa, J. (2022). Early fire detection based on gas sensor arrays: Multivariate calibration and validation. *Sensors and Actuators B: Chemical*, 352, 130961.
- Song, H. C., Kim, Y. L., Lee, D. H., & Song, J. B. (2017). Electric connector assembly based on vision and impedance control using cable connector-feeding system. *Journal of Mechanical Science and Technology*, 31, 5997-6003.
- Speiser, J. L., Miller, M. E., Tooze, J., & Ip, E. (2019). A comparison of random forest variable selection methods for classification prediction modeling. *Expert systems with applications*, 134, 93-101.
- Sullivan, A. L. (2017). Inside the inferno: Fundamental processes of wildland fire behaviour: Part 2: Heat transfer and interactions. *Current Forestry Reports*, 3, 150-171.

- Sun, X., Sun, L., & Huang, Y. (2021). Forest fire smoke recognition based on convolutional neural network. *Journal of Forestry Research*, 32(5), 1921-1927.
- Surya, L. (2017). Risk analysis model that uses machine learning to predict the likelihood of a fire occurring at a given property. *International Journal of Creative Research Thoughts (IJCRT)*, ISSN, 2320-2882.
- Süzen, A. A., Duman, B., & Şen, B. (2020, June). Benchmark analysis of jetson tx2, jetson nano and raspberry pi using deep-cnn. In 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA) (pp. 1-5). IEEE.
- Tabassum, H., Iqbal, M. M., Mahmood, Z., Parveen, M., & Ullah, I. (2023). Gender classification from anthropometric measurement by boosting decision tree: A novel machine learning approach. *Journal of the National Medical Association*.
- Taha, A., Hadi, A. S., Cosgrave, B., & McKeever, S. (2023). A multiple association-based unsupervised feature selection algorithm for mixed data sets. *Expert Systems with Applications*, 212, 118718.
- Tahmasebi, P., Kamrava, S., Bai, T., & Sahimi, M. (2020). Machine learning in geo-and environmental sciences: From small to large scale. *Advances in Water Resources*, 142, 103619.
- Taib, S., Jadin, M. S., & Kabir, S. (2011, April). Thermal imaging for qualitative-based measurements of thermal anomalies in electrical components. In *2011 Saudi International Electronics, Communications and Photonics Conference (SIEPC)* (pp. 1-6). IEEE.
- Taunk, K., De, S., Verma, S., & Swetapadma, A. (2019, May). A brief review of nearest neighbor algorithm for learning and classification. In 2019 international conference on intelligent computing and control systems (ICCS) (pp. 1255-1260). IEEE.
- Thabtah, F., Abdelhamid, N., & Peebles, D. (2019). A machine learning autism classification based on logistic regression analysis. *Health information science and systems*, 7(1), 12.
- Thomas, J., Joseph, B., Jose, J. P., Maria, H. J., Main, P., Ali Rahman, A., ... & Thomas, S. (2019). Recent advances in cross-linked polyethylene-based nanocomposites for high voltage engineering applications: a critical review. *Industrial & Engineering Chemistry Research*, 58(46), 20863-20879.
- Tian, F. C., Liang, Y. T., Zhu, H. Q., Chen, M. Y., & Wang, J. C. (2022). Application of a novel detection approach based on non-dispersive infrared theory to the in-situ analysis on indicator gases from underground coal fire. *Journal of Central South University*, 29(6), 1840-1855.
- Tian, S., Zhang, J., Shu, X., Chen, L., Niu, X., & Wang, Y. (2022). A novel evaluation strategy to artificial neural network model based on bionics. *Journal of Bionic Engineering*, 1-16.
- Toulouse, T., Rossi, L., Celik, T., & Akhloufi, M. (2016). Automatic fire pixel detection using image processing: a comparative analysis of rule-based and machine learning-based methods. *Signal, Image and Video Processing*, 10, 647-654.

- Tripathi, A. M., & Mishra, A. (2021). Self-supervised learning for environmental sound classification. *Applied Acoustics*, 182, 108183.
- Truong, C. T., Nguyen, T. H., Vu, V. Q., Do, V. H., & Nguyen, D. T. (2023). Enhancing fire detection technology: A UV-based system utilizing fourier spectrum analysis for reliable and accurate fire detection. *Applied Sciences*, 13(13), 7845.
- Tsanas, A., & Xifara, A. (2012). Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools. *Energy and buildings*, 49, 560-567.
- Turhan, N. S. (2020). Karl Pearson's Chi-Square Tests. *Educational Research and Reviews*, 16(9), 575-580.
- Türker, G. F., & Tanyeri, K. Blokzincir Teknolojisi ile Nesnelerin İnterneti Tabanlı (IoT) Sistemlerin Veri Güvenliğinin Sağlanması. *Gazi University Journal of Science Part C: Design and Technology*, 1-1.
- Ul-Hamid, A., Soufi, K. Y., Al-Hadhrami, L. M., & Shemsi, A. M. (2015). Failure investigation of an underground low voltage XLPE insulated cable. *Anti-Corrosion Methods and Materials*, 62(5), 281-287.
- Urhan, O., & Güllü, K. (2023). Veriye Dayalı Akıllı Şehir Oluşturmada Teknoloji Trendleri. *Şura Akademi*, (2), 19-25.
- Uzair, M., & Jamil, N. (2020, November). Effects of hidden layers on the efficiency of neural networks. In 2020 IEEE 23rd international multitopic conference (INMIC) (pp. 1-6). IEEE.
- Valikhujaev, Y., Abdusalomov, A., & Cho, Y. I. (2020). Automatic fire and smoke detection method for surveillance systems based on dilated CNNs. *Atmosphere*, 11(11), 1241.
- Velásquez, R. A. (2022). Influence of string-box size and the derating factor associated to the DC protection for PV solar panels. *Electric Power Systems Research*, 209, 107992.
- Venkata, P., & Pandya, V. (2022). Data mining model and Gaussian Naive Bayes based fault diagnostic analysis of modern power system networks. *Materials Today: Proceedings*, 62, 7156-7161.
- Verardi, L., Fabiani, D., & Montanari, G. C. (2014). Electrical aging markers for EPR-based low-voltage cable insulation wiring of nuclear power plants. *Radiation Physics and Chemistry*, 94, 166-170.
- Vishnukumar, H. J., Butting, B., Müller, C., & Sax, E. (2017, September). Machine learning and deep neural network—Artificial intelligence core for lab and real-world test and validation for ADAS and autonomous vehicles: AI for efficient and quality test and validation. In 2017 intelligent systems conference (IntelliSys) (pp. 714-721). IEEE.
- Vujović, V., & Maksimović, M. (2014, May). Raspberry Pi as a Wireless Sensor node: Performances and constraints. In 2014 37th international convention on information and communication technology, electronics and microelectronics (MIPRO) (pp. 1013-1018). IEEE.

- Wallace, S., Richardson, M., & Donat, W. (2021). Getting started with raspberry pi. Maker Media, Inc..
- Wan, X., Cai, J., Luo, S., Tian, Z., Zhang, L., & Xia, X. (2022, March). Gaussian Process for the Machine Learning-based Smart fire Detection System. In 2022 IEEE 6th Information Technology and Mechatronics Engineering Conference (ITOEC) (Vol. 6, pp. 100-104). IEEE.
- Wang, B., Rao, Z., Xie, Q., Wolański, P., & Rarata, G. (2017). Brief review on passive and active methods for explosion and detonation suppression in tubes and galleries. *Journal of Loss Prevention in the Process Industries*, 49, 280-290.
- Wang, F., Chawla, S., & Liu, W. (2013, November). Tikhonov or lasso regularization: Which is better and when. In 2013 IEEE 25th International Conference on Tools with Artificial Intelligence (pp. 795-802). IEEE.
- Wang, T., Zhang, C., Snoussi, H., & Zhang, G. (2020). Machine learning approaches for thermoelectric materials research. *Advanced Functional Materials*, 30(5), 1906041.
- Wang, Y., Wang, X., & Liu, W. (2016). Unsupervised local deep feature for image recognition. *Information Sciences*, 351, 67-75.
- Wang, Z., Zhang, T., Wu, X., & Huang, X. (2022). Predicting transient building fire based on external smoke images and deep learning. *Journal of Building Engineering*, 47, 103823.
- Web adresi 1: https://store.arduino.cc/collections/boards-modules?page=1&grid_list=list-view
- Wei, M. C., Lin, B. R., Lin, Y. Y., Chiou, G. J., & Kuo, W. K. (2021, October). Experimental Study on Effects of Light Source and Different Smoke Characteristics on Signal Intensity of Photoelectric Smoke Detectors. In 2021 IEEE 3rd Eurasia Conference on IOT, Communication and Engineering (ECICE) (pp. 518-522). IEEE.
- Wen, L., Ding, J., & Xu, Z. (2021). Multiframe detection of sea-surface small target using deep convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-16.
- Williams, C. K. (1998). Computation with infinite neural networks. *Neural Computation*, 10(5), 1203-1216.
- Wocker, M., Betz, N. K., Feuersänger, C., Lindworsky, A., & Deuse, J. (2020). Unsupervised learning for opportunistic maintenance optimization in flexible manufacturing systems. *Procedia CIRP*, 93, 1025-1030.
- Wong, T. T. (2015). Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation. *Pattern recognition*, 48(9), 2839-2846.
- Wu, Z., Hu, Y., Wen, J. X., Zhou, F., & Ye, X. (2020). A review for solar panel fire accident prevention in large-scale PV applications. *IEEE Access*, 8, 132466-132480.
- Wuest, T., Irgens, C., & Thoben, K. D. (2014). An approach to monitoring quality in manufacturing using supervised machine learning on product state data. *Journal of Intelligent Manufacturing*, 25, 1167-1180.

- Xavier, K. L. B. L., & Nanayakkara, V. K. (2022). Development of an early fire detection technique using a passive infrared sensor and deep neural networks. *Fire Technology*, 58(6), 3529-3552.
- Xin, X., Tu, Y., Stojanovic, V., Wang, H., Shi, K., He, S., & Pan, T. (2022). Online reinforcement learning multiplayer non-zero sum games of continuous-time Markov jump linear systems. *Applied Mathematics and Computation*, 412, 126537.
- Xu, H., Li, Y., Huang, N. J., Yu, Z. R., Wang, P. H., Zhang, Z. H., ... & Tang, L. C. (2019). Temperature-triggered sensitive resistance transition of graphene oxide wide-ribbons wrapped sponge for fire ultrafast detecting and early warning. *Journal of hazardous materials*, 363, 286-294.
- Xu, H., Tang, T., Zhang, B., & Liu, Y. (2022). Identification of two-phase flow regime in the energy industry based on modified convolutional neural network. *Progress in Nuclear Energy*, 147, 104191.
- Xu, X., Du, H., & Lian, Z. (2022). Discussion on regression analysis with small determination coefficient in human-environment researches. *Indoor air*, 32(10), e13117.
- Xu, Z., & Saleh, J. H. (2021). Machine learning for reliability engineering and safety applications: Review of current status and future opportunities. *Reliability Engineering & System Safety*, 211, 107530.
- Yadav, S., & Shukla, S. (2016, February). Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In 2016 IEEE 6th International conference on advanced computing (IACC) (pp. 78-83). IEEE.
- Yeon, Y. M., & Kim, S. H. (2020). Analysis of the risk of heat generation due to bolt loosening in terminal block connector parts. *Fire Science and Engineering*, 34(3), 67-75.
- Yılmaz, F., & Özdemir, S. (2023). Nesnelerin İnterneti Araçlarının Uzaktan Eğitimde Kullanımı: Sistemik Alan Yazın Taraması. *Mersin Üniversitesi Eğitim Fakültesi Dergisi*, 19(3), 394-414.
- Yu, S., Zhang, Z., Liang, X., Wu, J., Zhang, E., Qin, W., & Xie, Y. (2019, November). A Matlab toolbox for feature importance ranking. In 2019 International Conference on Medical Imaging Physics and Engineering (ICMIPE) (pp. 1-6). IEEE.
- Yuan, X., Gu, L., Wei, Z., Ding, W., Ma, Q., & Guo, J. (2024). Bootstrap sampling style ensemble neural network for inverse design of optical nanoantennas. *Optics Communications*, 557, 130296.
- Zainudin, W. M. L. W., Shauri, R. L. A., Roslan, M. I., Rosli, M. A., & Ariffin, M. F. M. (2020, July). New Interface using Beaglebone Black for 4-DOF Robot Arm System. In 2020 IEEE Symposium on Industrial Electronics & Applications (ISIEA) (pp. 1-6). IEEE.
- Zanghieri, M., Benatti, S., Benini, L., & Donati, E. (2023, June). Event-based Low-Power and Low-Latency Regression Method for Hand Kinematics from Surface EMG. In 2023 9th International Workshop on Advances in Sensors and Interfaces (IWASI) (pp. 293-298). IEEE.

- Zarapelão, B. B., Miani, R. S., Kawakani, C. T., & de Alvarenga, S. C. (2017). A survey of intrusion detection in Internet of Things. *Journal of Network and Computer Applications*, 84, 25-37.
- Zhang, J., Huang, L., Chen, T., & Su, G. (2021). Simulation based analysis of electrical fire risks caused by poor electric contact between plug and receptacle. *Fire safety journal*, 126, 103434.
- Zhang, P., Zhang, Y., Wang, X., Yang, J., & Han, W. (2021). Effect of Acetylated SEBS/PP for Potential HVDC Cable Insulation. *Materials*, 14(7), 1596.
- Zhang, Y., Geng, P., Sivaparthipan, C. B., & Muthu, B. A. (2021). Big data and artificial intelligence based early risk warning system of fire hazard for smart cities. *Sustainable Energy Technologies and Assessments*, 45, 100986.
- Zhang, Y., Tang, K., Liu, Z., & Chen, Y. (2021). Experimental study on thermal and fire behaviors of energized PE-insulated wires under overload currents. *Journal of Thermal Analysis and Calorimetry*, 145, 345-351.
- Zhao, Z., Morstatter, F., Sharma, S., Alelyani, S., Anand, A., & Liu, H. (2010). Advancing feature selection research. ASU feature selection repository, 1-28.
- Zhdanova, A., Volkov, R., Sviridenko, A., Kuznetsov, G., & Strizhak, P. (2022). Influence of compartment fire behavior at ignition and combustion development stages on the operation of fire detectors. *Fire*, 5(3), 84.

ÖZGEÇMİŞ

Ad-Soyad : Muhammed Fatih PEKŞEN

ÖĞRENİM DURUMU:

- Lisans** : 2005, Yeditepe Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği (İngilizce)
- Yükseklisans** : 2018, Sakarya Üniversitesi, Yangın ve Yangın Güvenliği Anabilim Dalı, Yangın ve Yangın Güvenliği

MESLEKİ DENEYİM

- 2006, 2012 yılları arasında aile şirketine çalıştı.
- 2012-2018 yılları arasında yarı zamanlı öğretim görevlisi olarak çalıştı.
- 2014 -2018 yılları arasında, otomotiv sanayisinde çeşitli projelerde iş güvenliği ve proje mühendisi olarak çalıştı.
- 2018 yılında Sakarya Üniversitesi'nde tam zamanlı öğretim görevlisi olarak çalışmaya başladı.

TEZDEN TÜRETİLEN ESERLER:

- Pekşen, M. F., Yurtsever, U., & Uyaroğlu, Y. (2024). Enhancing electrical panel anomaly detection for predictive maintenance with machine learning and IoT. Alexandria Engineering Journal, 96, 112-123.