

**YAPAY ZEKÂ YÖNTEMLERİ KULLANILARAK AKILLI EV
SİSTEMİ GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

Cevdet Tamer GÜVEN

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

**MERSİN
OCAK - 2020**

**YAPAY ZEKÂ YÖNTEMLERİ KULLANILARAK AKILLI EV
SİSTEMİ GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

Cevdet Tamer GÜVEN

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**




**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

**Danışman
Dr. Öğr. Üyesi Mehmet ACI**

**MERSİN
OCAK - 2020**

ONAY

Cevdet Tamer GÜVEN tarafından Dr. Öğr. Üyesi Mehmet ACI danışmanlığında hazırlanan “Yapay Zekâ Yöntemleri Kullanılarak Akıllı Ev Sistemi Geliştirilmesi” başlıklı çalışma aşağıda imzaları bulunan jüri üyeleri tarafından 14/01/2020 tarihinde yapılan Tez Savunma Sınavı sonucunda oy birliği/çokluğu ile Yüksek Lisans tezi olarak kabul edilmiştir.

Görevi	Ünvanı, Adı ve Soyadı	İmza
Başkan	Dr. Öğr. Üyesi Mehmet ACI	
Üye	Prof. Dr. Zeki YETGİN	
Üye	Dr. Öğr. Üyesi Ahmet AYDIN	

Yukarıdaki Jüri kararı Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 27/02/2020 tarih ve 2020-179/05 sayılı kararıyla onaylanmıştır.



Bu tezde kullanılan özgün bilgiler, şekil, tablo ve fotoğraflardan kaynak göstermeden alıntı yapmak 5846 sayılı Fikir ve Sanat Eserleri Kanunu hükümlerine tabidir.

ETİK BEYAN

Mersin Üniversitesi Lisansüstü Eğitim-Öğretim Yönetmeliğinde belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada,

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlâk kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak kullandığımı,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Bu tezin herhangi bir bölümünü Mersin Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı,
- Tezin tüm telif haklarını Mersin Üniversitesi'ne devrettiğimi

beyan ederim.

ETHICAL DECLARATION

This thesis is prepared in accordance with the rules specified in Mersin University Graduate Education Regulation and I declare to comply with the following conditions:

- I have obtained all the information and the documents of the thesis in accordance with the academic rules.
- I presented all the visual, auditory and written informations and results in accordance with scientific ethics.
- I refer in accordance with the norms of scientific works about the case of exploitation of others' works.
- I used all of the referred works as the references.
- I did not do any tampering in the used data.
- I did not present any part of this thesis as an another thesis at Mersin University or another university.
- I transfer all copyrights of this thesis to the Mersin University.

14/01/2020



Cevdet Tamer GÜVEN

ÖZET

YAPAY ZEKÂ YÖNTEMLERİ KULLANILARAK AKILLI EV SİSTEMİ GELİŞTİRİLMESİ

Akıllı ev sistemleri, genellikle akıllı ev uygulamalarıyla elektronik cihazların kontrol edilmesine izin veren ve ev sahiplerine güvenlik, konfor ve enerji verimliliği sağlayan sistemlerdir. Özellikle Nesnelerin İnterneti (IOT) ile birlikte bu sistemler her alanda kendilerine yer bulmuşlardır. Akıllı ev sistemleri ile kullanıcılar, bağlı oldukları ev sistemlerini uzaktan ya da ev içerisinden kontrol edebilmektedirler. Aynı zamanda uzaktan kontrolün yanı sıra akıllı ev sistemindeki güvenlik kontrolleri ile ev sakinlerinin gündelik yaşamlarını daha güvenli bir şekilde geçirmelerini sağlamaktadırlar. Bu tez çalışmasında, Raspberry Pi (RPI), Arduino ve çeşitli sensörler kullanılarak bir akıllı ev sistemi geliştirilmiştir. Geliştirilen akıllı ev sisteminin birçok farklı modu olup, ev sakinlerinin durumlarına göre sistemin kontrol şekli değişebilmektedir. Sistem, sıradan akıllı ev sistemlerinde olan uzaktan kontrol ve güvenlik sistemlerinin yanı sıra yapay zekâ algoritmaları ile rutin aktiviteleri algılayarak bazı önemli işlemleri kullanıcı yararına otonom olarak yapabilmektedir. Sistemin eğitimi için kullanılan veri kümesi ev içerisindeki sensörlerden alınan ve sanal verilerden oluşmaktadır. Sistemdeki verileri işlemek ve kontrolleri sağlamak için Python ve Arduino yazılım ortamları kullanılmıştır. Çalışmada yapay zekâ yöntemleri olarak Naive Bayes, Ensemble, Genel linear, karar ağacı, destek vektör makinesi (SVM), K-en yakın komşu (KNN), Gauss süreç (GPC) ve yapay sinir ağı (YSA) modelleri kullanılmış ve modellerin başarıları kıyaslanmıştır. Yöntemler arasındaki en başarılı sonuçlar; 0.9794 doğruluk ile GPC modeli, 0.9653 doğruluk ile Ensemble modelleri içerisindeki rassal orman algoritması (RF) ve 0.9651 doğruluk ile Genel linear modeller içerisindeki Stochastic gradient descent (SGD) algoritması ile elde edilmiştir. Çalışmada elde edilen sonuçlar, akıllı ev sistemlerinde yapay zekâ algoritmalarının kullanımının uygun olduğunu göstermektedir.

Anahtar Kelimeler: Akıllı Ev Sistemi, Yapay Zekâ, Uzaktan Kontrol, Güvenlik Sistemi.

Danışman: Doktor Öğretim Üyesi, Mehmet ACI, Mersin Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Mersin.

ABSTRACT

DEVELOPMENT OF SMART HOME SYSTEM USING ARTIFICIAL INTELLIGENCE METHODS

Smart home systems are generally systems that allow the control of electronic devices through smart home applications and provide homeowners with safety, comfort and energy efficiency. Especially with the Internet of Things (IoT), these systems have found their place in every field. With smart home systems, users can control their home systems remotely or from within the home. At the same time, remote control as well as the security controls in the smart home system allows residents to spend their daily lives more safely. In this thesis, a smart home system was developed by using Raspberry Pi (RPi), Arduino and various sensors. There are many different modes of the smart home system developed and the control of the system may change according to the situation of the residents. In addition to remote control and security systems in ordinary smart home systems, the system can detect routine activities with artificial intelligence algorithms and perform some important operations autonomously to the user wound. The data set used for training the system consists of data from sensors in the house and virtual data. Python and Arduino software environments are used to process and control data in the system. In this study, Naive Bayes, Ensemble, General linear, decision tree, support vector machine (SVM), K-nearest neighbor (KNN), Gauss process (GPC) and artificial neural network (ANN) models were used as artificial intelligence methods and their successes were compared. The most successful results among the methods; GPC with 0.9794 accuracy, random forest algorithm (RF) in Ensemble models with 0.9653 accuracy and Stochastic gradient descent (SGD) algorithm in General linear models with 0.9651 accuracy. The results obtained in this study show that the use of artificial intelligence algorithms in smart home systems is appropriate.

Keywords: Smart Home System, Artificial Intelligence, Remote Control, Security System.

Advisor: Asst. Prof., Mehmet ACI, Department of Computer Engineering, University of Mersin, Mersin.

TEŐEKKÜR

Yüksek lisans eğitimim boyunca kıymetli bilgi, birikim ve tecrübeleri ile bana yol gösterici ve destek olan, her türlü konuda yardımını esirgememiş değerli danışman hocam sayın Dr. Öğr. Üyesi Mehmet ACI'ya sonsuz teşekkür ve saygılarımı sunarım.

Hayatım boyunca maddi manevi destekleriyle beni hiçbir zaman yalnız bırakmayan annem Mahperi KOCA'ya, babam Mustafa Meray GÜVEN'e, ablam Hatice SEYHAN'a ve tez aşamasında dünyaya gelen yeğenim Yamaç Demir SEYHAN'a sonsuz teşekkürler ederim. Lisans ve yüksek lisans hayatım boyunca her zaman yanımda olan, hiçbir konuda desteğini esirgememiş değerli arkadaşım Derya YERGÖK'e tüm kalbimle teşekkür ederim.

Bu çalışma, Mersin Üniversitesi Bilimsel Araştırma Projeleri Bölümü tarafından desteklenmektedir (Proje Numarası: 2019-1-TP2-3222).

Tez sunumumda yer alan değerli jüri üyeleri; Prof. Dr. Zeki YETGİN ve Dr. Öğr. Üyesi Ahmet AYDIN'a katılımlarından dolayı teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
İÇ KAPAK	ii
ONAY	iii
ETİK BEYAN	iv
ÖZET	v
ABSTRACT	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
TABLolar DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
KISALTMALAR ve SİMGELER	xiii
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMALARI	3
2.1. Literatürde Bluetooth Tabanlı Sistemler Üzerine Yapılmış Çalışmalar	3
2.2. Literatürde GSM Tabanlı Sistemler Üzerine Yapılmış Çalışmalar	5
2.3. Literatürde İnternet Tabanlı Sistemler Üzerine Yapılmış Çalışmalar	7
2.4. Literatürde ZigBee Tabanlı Sistemler Üzerine Yapılmış Çalışmalar	9
2.5. Literatürde RFID Tabanlı Sistemler Üzerine Yapılmış Çalışmalar	11
2.6. Literatürde Yapay Zekâ Tabanlı Sistemler Üzerine Yapılmış Çalışmalar	12
3. MATERYAL ve YÖNTEM	14
3.1. Problemin Tanımı	14
3.2. Materyaller	15
3.2.1. Veri Kümesi	15
3.2.2. Donanım	19
3.2.2.1. Mikrodenetleyici Kartları	19
3.2.2.2. Sensör ve Elektronik Bileşenler	21
3.2.3. Geliştirme Ortamı	30
3.3. Akıllı Ev Yönetim Sistemi	33
3.4. Yöntemler	38
3.4.1. Lojistik Regresyon Algoritması	38
3.4.2. Naive Bayes Algoritması	39
3.4.2.1. Gaussian Naive Bayes Algoritması	40
3.4.2.2. Bernoulli Naive Bayes Algoritması	40
3.4.2.3. Multinomial Naive Bayes Algoritması	41
3.4.2.4. Complement Naive Bayes Algoritması	42
3.4.3. K-En Yakın Komşu Algoritması	43
3.4.4. Karar Ağaçları Algoritması	44
3.4.5. Destek Vektör Makineleri Algoritması	46
3.4.6. XGBoost Algoritması	47
3.4.7. Çok Katmanlı Perceptron Algoritması	48
3.4.8. Rassal Orman Algoritması	49
3.4.9. Stochastic Gradient Descent Algoritması	51
3.4.10. Gaussian Süreç Algoritması	52
3.4.11. Gradient Tree Boosting Algoritması	53
3.4.12. Pasif Agresif Sınıflandırma Algoritması	54
4. BULGULAR ve TARTIŞMA	55
4.1. Naive Bayes Modeller	56
4.1.1. Gaussian Naive Bayes	56
4.1.2. Bernoulli Naive Bayes	56
4.1.3. Multinomial Naive Bayes	57
4.1.4. Complement Naive Bayes	58
4.2. Ensemble Modeller	59

	Sayfa
4.2.1. Rassal Orman Algoritması	59
4.2.2. Gradient Tree Boosting Algoritması	60
4.2.3. XGBoost Algoritması	61
4.3. Genel Linear Modeller	63
4.3.1. Lojistik Regresyon Algoritması	63
4.3.2. Stochastic Gradient Descent Algoritması	63
4.3.3. Pasif Agresif Sınıflandırma Algoritması	64
4.4. Karar Ağacı Modeli	66
4.5. Destek Vektör Makinesi Modeli	67
4.6. K-En Yakın Komşu Modeli	68
4.7. Gauss Süreç Modeli	69
4.8. Yapay Sinir Ağı Modeli	71
5. SONUÇLAR ve ÖNERİLER	73
KAYNAKLAR	75
ÖZGEÇMİŞ	83



TABLULAR DİZİNİ

	Sayfa
Tablo 3.1. Veri kümesi	15
Tablo 3.2. Veri kümesi içeriği	16
Tablo 3.3. Arduino Nano özellikleri	20
Tablo 3.4. RPi 3 Model B+ özellikleri	21
Tablo 4.1. Gaussian Naive Bayes sınıflandırma raporu	56
Tablo 4.2. Gaussian Naive Bayes karmaşıklık matrisi	56
Tablo 4.3. Bernoulli Naive Bayes sınıflandırma raporu	57
Tablo 4.4. Bernoulli Naive Bayes karmaşıklık matrisi	57
Tablo 4.5. Multinomial Naive Bayes sınıflandırma raporu	57
Tablo 4.6. Multinomial Naive Bayes karmaşıklık matrisi	58
Tablo 4.7. Complement Naive Bayes sınıflandırma raporu	58
Tablo 4.8. Complement Naive Bayes karmaşıklık matrisi	58
Tablo 4.9. RF algoritması sınıflandırma Raporu	60
Tablo 4.10. RF algoritması karmaşıklık matrisi	60
Tablo 4.11. Gradient Tree Boosting algoritması sınıflandırma raporu	61
Tablo 4.12. Gradient Tree Boosting algoritması karmaşıklık matrisi	61
Tablo 4.13. XGBoost algoritması sınıflandırma raporu	61
Tablo 4.14. XGBoost algoritması karmaşıklık matrisi	62
Tablo 4.15. LR algoritması sınıflandırma raporu	63
Tablo 4.16. LR algoritması karmaşıklık matrisi	63
Tablo 4.17. SGD algoritması sınıflandırma raporu	64
Tablo 4.18. SGD algoritması karmaşıklık matrisi	64
Tablo 4.19. PAC algoritması sınıflandırma raporu	64
Tablo 4.20. PAC algoritması karmaşıklık matrisi	65
Tablo 4.21. Karar ağacı algoritması sınıflandırma raporu	66
Tablo 4.22. Karar ağacı algoritması karmaşıklık matrisi	66
Tablo 4.23. SVM algoritması sınıflandırma raporu	67
Tablo 4.24. SVM algoritması karmaşıklık matrisi	68
Tablo 4.25. KNN algoritması sınıflandırma raporu	69
Tablo 4.26. KNN algoritması karmaşıklık matrisi	69
Tablo 4.27. GPC algoritması sınıflandırma raporu	70
Tablo 4.28. GPC karmaşıklık matrisi	70
Tablo 4.29. MLP algoritması sınıflandırma raporu	71
Tablo 4.30. MLP algoritması karmaşıklık matrisi	71

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Veri kümesinin görselleştirmesi-1	17
Şekil 3.2. Veri kümesinin görselleştirmesi-2	17
Şekil 3.3. Evde olma durumuna göre sıcaklık ve nem değerleri	18
Şekil 3.4. Günlere göre evde olma durumları	18
Şekil 3.5. Arduino Nano mikrodenetleyici kartı	19
Şekil 3.6. RPi 3 Model B+	20
Şekil 3.7. LDR sensörü	22
Şekil 3.8. Alev algılama sensörü	22
Şekil 3.9. MQ5 yanıcı gaz algılama sensörü	23
Şekil 3.10. Çift kanallı röle modülü	23
Şekil 3.11. Yağmur algılama sensörü	24
Şekil 3.12. Ses sensörü	24
Şekil 3.13. DHT11 sıcaklık ve nem sensörü	25
Şekil 3.14. PIR sensörü	25
Şekil 3.15. Kamera modülü	26
Şekil 3.16. Fan modülü	26
Şekil 3.17. Servo motor	27
Şekil 3.18. GSM modülü	27
Şekil 3.19. LM2596 voltaj regülatörü	28
Şekil 3.20. MCP3008 entegresi	28
Şekil 3.21. GPIO çoklu kablo modülü	29
Şekil 3.22. Breadboard	29
Şekil 3.23. Şerit led	30
Şekil 3.24. Raspbian OS	31
Şekil 3.25. Python terminal	32
Şekil 3.26. Scikit-Learn algoritma şeması	32
Şekil 3.27. Arduino IDE	33
Şekil 3.28. Akıllı ev sistemi	34
Şekil 3.29. Akıllı ev sistemi android kontrol ara yüzü	35
Şekil 3.30. Akıllı ev sistemi web kontrol ara yüzü	36
Şekil 3.31. Akıllı ev sistemi kamera izleme ara yüzü	36
Şekil 3.32. Akıllı ev sistemi devre şeması	37
Şekil 3.33. KNN yapısı	44
Şekil 3.34. Karar ağacı yapısı	45
Şekil 3.35. Doğrusal SVM	46
Şekil 3.36. Doğrusal olmayan SVM	47
Şekil 3.37. Tek katmanlı MLP ağı	48
Şekil 3.38. Rassal orman algoritması	50
Şekil 3.39. GD algoritması tarafından alınan yol	51
Şekil 3.40. SGD algoritması tarafından alınan yol	52
Şekil 3.41. Gradient Tree Boosting algoritması	53
Şekil 4.1. Naive Bayes modellerinin kalibrasyon grafikleri (güvenilirlik eğrisi)	59
Şekil 4.2. Naive Bayes modellerinin öğrenme eğrisi	59
Şekil 4.3. Ensemble modellerinin kalibrasyon grafikleri (güvenilirlik eğrisi)	62
Şekil 4.4. Ensemble modellerinin öğrenme eğrisi	62
Şekil 4.5. Genel Linear modellerinin kalibrasyon grafikleri (güvenilirlik eğrisi)	65
Şekil 4.6. Genel Linear modellerinin öğrenme eğrisi	65
Şekil 4.7. Karar ağacı modelinin öğrenme eğrisi	67
Şekil 4.8. SVM modelinin öğrenme eğrisi	68
Şekil 4.9. KNN modelinin öğrenme eğrisi	69
Şekil 4.10. GPC modelinin öğrenme eğrisi	70



KISALTMALAR ve SİMGELER

Kısaltma/Simge	Tanım
ADK	Accessory Development Kit (Aksesuar Geliştirme Kartı)
ARM	Acorn RISK Machine
BLE	Bluetooth Low Energy (Bluetooth Düşük Enerji)
CART	A Classification and Regression Tree (Sınıflandırma ve Regresyon Ağaçları)
DC	Direct Current (Doğru Akım)
ETSI	European Telecommunications Standards Institute (Avrupa Telekomünikasyon Standartları Enstitüsü)
GD	Gradient Descent (Dereceli Azalma)
GPC	Gaussian Process Classifier (Gaussian Süreç Sınıflandırması)
GPRS	General Packet Radio Service (Genel Paket Radyo Servisi)
GPS	Global Positioning System (Küresel Konumlama Sistemi)
GSM	Global System for Mobile Communications (Mobil iletişim için Küresel Sistem)
GUI	Graphical User Interface (Grafiksel Kullanıcı Arabirimi)
IDE	Integrated Development Environment (Bütünleşik Geliştirme Ortamı)
IEEE	Institute of Engineers and Everyone Else (Elektronik Mühendisleri Enstitüsü)
IOT	İnternet Of Things (Nesnelerin İnterneti)
IP	Internet Protocol (İnternet Protokolü)
IR	Infrared (Kızılötesi)
KNN	K-Nearest Neighborhood (K-En Yakın Komşu)
LCD	Liquid Crystal Display (Sıvı Kristal Ekran)
LDR	Light Dependent Resistor (Işığa Bağımlı Direnç)
LR	Logistic Regression (Lojistik Regresyon)
MLP	Multilayer Perceptron (Çok Katmanlı Perceptron)
MMS	Multimedia Messaging Service (Çoklu Ortam Mesajlaşma Servisi)
NFC	Near Field Communication (Yakın Alan İletişimi)
OS	Operating System (İşletim Sistemi)
PAC	Passive Agressive Classifier (Pasif Agresif Sınıflandırıcı)
PCB	Printed Circuit Board (Baskılı Devre Kartı)
PIR	Passive Infrared Sensor (Pasif Kızılötesi Sensör)
PLC	Programmable Logic Controller (Programlanabilir Lojik Kontrolör)
PWM	Pulse Width Modulation (Sinyal Genişlik Modülasyonu)
RBF	Radial Based Function (Radyal Tabanlı Fonksiyon)
RFID	Radio Frequency Identification (Radyo Frekanslı Tanımlama)
RPi	Raspberry Pi
SGD	Stochastic Gradient Descent (Stokastik Dereceli Azalma)
SMS	Short Messaging Service (Kısa Mesaj Servisi)
SRAM	Static Random Access Memory (Statik Rastgele Erişimli Bellek)
SVM	Support Vector Machine (Destek Vektör Makineleri)
UHF	Ultra High Frequency (Ultra Yüksek Frekans)
WSN	Wireless Sensor Network (Kablosuz Sensör Ağları)
YSA	Yapay Sinir Ağları

1. GİRİŞ

Günümüzde gelişen teknoloji ile birlikte insanların hayatlarını kolaylaştıran teknolojik gelişmeler günlük hayatımızın vazgeçilmezleri arasında üst sıralarda yerlerini almaktadır. Teknolojideki gelişmeler insanların hayatlarını kolaylaştırmanın yanı sıra gündelik hayatımızdaki insan kaynaklı olası hataları önleme ve güvenliği sağlama amacını da taşırlar. Bu gelişmelerin başında otomasyon sistemleri gelmektedir. Sanayi devrimi ile birlikte üretimin artması ve insan gücüyle üretimin maliyetli olması nedeniyle otomasyon sistemleri geliştirilmiştir. Otomasyon, bir sistemin belirli bir aktivite doğrultusunda kullanıcıdan bağımsız bir şekilde istenilen işlemleri gerçekleştirmesidir [1]. Otomasyon sistemlerinde daha az insan gücüne bağlı olarak daha az insan kaynaklı hata, daha az maliyet ve daha hızlı üretim sayesinde robotik elemanlar tercih sebebi olmuştur. Otomasyonda robotik sistemlerin kullanılması üretimin; hızlı, ekonomik, minimum hatalı ve kaliteli olmasını sağlamıştır. İmalat, inşaat, elektrik-elektronik, sanayi, geri dönüşüm, tekstil gibi farklı sektörlerde otomasyon sistemleri kullanılmaktadır. Günümüzdeki inşaat sektöründe kullanılan otomasyon sistemlerine akıllı ev sistemleri/otomasyonu en güzel örnektir. Ev otomasyonu kavramı 1970'lerin sonlarından bu yana teknoloji ile birlikte gelişmiştir. Ancak teknolojinin ve hizmetlerin gelişmesiyle birlikte, insanların bir evin ne yapması gerektiği veya hizmetlerin evde nasıl sağlanacağı konusundaki beklentileri zaman içerisinde değişikliğe uğramıştır [2]. Günümüzde bu sistemlere akıllı ev sistemleri denilmektedir.

Akıllı ev sistemleri, daha iyi bir yaşam kalitesi için teknoloji ve hizmetlerin ağ yoluyla bütünleşmesidir. Gündelik ev işlerini ve faaliyetlerini kullanıcı müdahalesi olmadan veya kullanıcının uzaktan kontrolü ile daha kolay bir şekilde gerçekleştirmektedir [3]. Akıllı ev sistemlerinde genelde bağlantı türü olarak Bluetooth, internet, ZigBee, yakın alan iletişimi (NFC), mobil iletişim için küresel sistem (GSM) ve radyo frekanslı tanımlama (RFID) kullanılmaktadır [4]. Bu sistemlerde genellikle akıllı ampuller, akıllı anahtarlar, güvenlik kameraları, kapı kilitleri ve beyaz eşyalar uzaktan kablosuz olarak kontrol edilebilmektedir. Sürekli artan teknolojik aygıtlar hayatımızı kolaylaştırır da hepsinin ayrı ayrı kontrolü güç ve maliyet bakımından çok zorlaşmaktadır. İnternet ve kablosuz iletişim teknolojilerinin geliştiği günümüzde, neredeyse her teknolojik aygıt internet üzerinden kontrol edilebilmektedir. Yapılan araştırmalarda 2015'te 25 milyar cihazın internete bağlı olduğu hesaplanmıştır. Bu rakamların 2020'de 50 milyar seviyesine çıkması beklenmektedir [5]. Neredeyse tüm elektrikli cihazların internete bağlanarak gündelik hayatımıza entegre edilmesini öngören teknoloji nesnelerin interneti (IOT) olarak tanımlanmaktadır. Kablosuz iletişimin gelişmesi, internet hız ve bant genişliklerinin artması, akıllı telefon ve aygıtların yaygınlaşması ve herkes tarafından kabul görmesi IOT teknolojisini büyük ölçüde hızlandıran ve geliştiren etmenlerdir. Tüm faydaların yanı sıra IOT teknolojisi

gelecekte bazı sorunlara da yol açacaktır. Bu kadar çok teknolojik aygıtın internete bağlanması ve kontrol edilebilmesi, sistemlerin siber güvenlik açıklarının artmasına neden olmaktadır. Aynı zamanda IOT cihazlar sayesinde özel bilgilerimizi internet üzerine kayıt etmemiz var olan veri boyutlarını önemli ölçüde arttırmaktadır [6]. Büyük verilerin işlenmesi çok zor ve karmaşık olduğu gibi bu verilerin güvenliği ve gizliliği de önemli hale gelmektedir. IOT cihazlar tarafından üretilen büyük veriler bulut bilişimin yaygınlaşmasını sağlamıştır. Bulut bilişim, günümüzde büyük veri işleme için yaygın olarak kullanılan bir teknolojidir [7]. Teknolojideki bu hızlı ilerleme ile artık sıradan bir insan bile kendi sistemlerini tasarlayıp bunları kullanabilmektedir. Farklı özelliklere sahip, her bütçeye uygun ve son derece ulaşılabilir olan geliştirme kartlarının piyasaya yayılması insanları kendi sistemlerini kurmaya teşvik etmektedir. Yaygın olarak kullanılan geliştirme kartları; Raspberry Pi (RPi), Arduino, Asus Tinker Board, Particle Photon, Intel Galileo ile Edison, Samsung ARTIK, BeagleBone gibi kartlardır [8]. Bunun gibi kartlarla yapılabilecekler sadece hayal gücüyle sınırlıdır. Büyük teknoloji şirketleri de bu akıma destek olmak için çeşitli geliştirme kartları üretmişlerdir. Örnek olarak Raspberry Pi Vakfı'nın geliştirdiği RPi kartı ve Asus'un Tinker Board kartı, bir bilgisayarda var olan özelliklerin neredeyse hepsine sahip geliştirme kartlarıdır. Intel şirketi IOT için, Galileo ve Edison gibi yüksek işlem gücüne sahip geliştirme kartları üretmiştir. Ülkemizde de yerli girişimlerle üretilen PICKAT, PIC ULAK, IOTURKS IOPHY ONE gibi geliştirme kartları üretilmektedir. Bu kartlarla bazı kişi ve firmalar tarafından geliştirilen akıllı ev sistemleri mevcuttur. Günümüzde kullanılan akıllı ev sistemleri, ev sakinlerinin evdeki durumları uzaktan takip edebilmesini ve bazı elektronik eşyaların uzaktan kontrolünü sağlamaktadır.

Bu tez çalışmasında, RPi, Arduino ve çeşitli sensörlerle çalışan yapay zekâ tabanlı bir akıllı ev sistemi geliştirilmiştir. Geliştirilen sistem, standart akıllı ev sistemlerinin yapabildiği aktiviteleri yapabilmekte ve yapay zekâ yazılımı sayesinde sürekli aktiviteleri algılayarak, bazı işlemleri ev sakinlerinden bağımsız olarak gerçekleştirmektedir.

2. KAYNAK ARAŞTIRMALARI

Bu bölümde, literatürde akıllı ev sistemleri üzerine yapılmış çalışmalar sunulmuştur. Akıllı ev kavramı, ev sakinlerinin ihtiyaçlarına karşılık verebilen, onlara daha konforlu, daha güvenli ve ekonomik bir yaşam sunan evler için kullanılmaktadır [9]. Akıllı ev sistemleri, çok hızlı bir gelişme göstermiş ve kısa sürede kablosuz sistemler geliştirilmiş ve piyasaya sürülmüştür [10].

2.1. Literatürde Bluetooth Tabanlı Sistemler Üzerine Yapılmış Çalışmalar

Bluetooth teknolojisi, insanların evlerindeki ve ofislerindeki dijital cihazları algılamada ve kontrol etmede devrim yaratacak şekilde tasarlanmıştır. Artık sadece bireysel cihazların kullanıldığı sistemler yerine yerleşik Bluetooth teknolojisiyle cihazların birbirleriyle iletişim kurabileceği bir ağ oluşturmak mümkündür. Bluetooth teknolojisi, ev otomasyonu için uygun maliyetli bir şekilde kullanılabilir. Bluetooth teknolojisi genelde 802.15.1 standardı ile 2.4 GHz frekansı üzerinden çalışmaktadır [11].

Naresh ve arkadaşları [12], Bluetooth tabanlı ev otomasyon ve güvenlik sistemi geliştirmişlerdir. Geliştirdikleri sistem, Bluetooth ile kablosuz olarak evdeki ışık, kapı, klima vb. elektronik cihazları kontrol etmeyi amaçlamaktadır. Bu sayede sistem, kablosuz kontrolün yanı sıra ev güvenliği ve enerji tasarrufu da sağlamaktadır. Geliştirilen ev otomasyon ve güvenliğinin temel amacı, engelli veya yaşlı olan ev sakinlerinin ev aletlerini kolaylıkla kontrol etmelerini ve acil durumlarda ev sakinlerinin uyarılmalarını sağlamaktır. Sistemin temelinde ARM7 LPC2148 ve ARM9 S3C2440A geliştirme kartları kullanılmıştır. Kablosuz olarak kontrol edilmek istenen elektrikli ev aletleri ARM7'ye bağlanıp, ARM7 ile ARM9 arasında Bluetooth bağlantısı oluşturulmuştur. Böylece ev sakinlerinin ARM9 kartı üzerinden sistemdeki elektrikli ev aletlerinin kontrolünü sağlayabilmesi ve sistemin durumunu ARM9 kartı üzerindeki ekrandan takip edebilmesi sağlanmıştır.

Asadullah ve Ullah [13], Arduino geliştirme kartı, Bluetooth modülü, akıllı telefon, ultrasonik mesafe sensörü ve toprak nem sensörü kullanarak düşük maliyetli ve kullanıcı dostu uzaktan kumandalı bir ev otomasyon sistemi geliştirmişlerdir. Geliştirdikleri sistem, su seviye tespiti için ultrasonik sensör ve otomatik bitki sulama için toprak nem sensörü kullanmaktadır. Ev otomasyon sisteminin prototipi donanım üzerine uygulanmış ve başarılı sonuçlar elde edilmiştir.

Yan ve Shi [14], Android telefonlar ile yönetilebilen, Bluetooth tabanlı bir ev aydınlatma kontrol sistemi geliştirmişlerdir. Akıllı yaşam sistemi adını verdikleri sistemin prototipini tasarlayıp test etmişlerdir. Daha sonra akıllı telefon kullanan kullanıcıların ev ışıklarını izleyip

kontrol edebilecekleri Android uygulamasının tasarımını ve prototipini uygulamışlardır. Çalışma sonucunda başarılı sonuçlara ulaşmışlardır.

Collotta ve Pau [15], ev sistemlerinde akıllı enerji yönetimi için bulanık tabanlı bir çözüm önermişlerdir. Çalışmada Bluetooth düşük enerji (BLE) teknolojisi ile ev enerji yönetimini düzenlemek için bulanık mantık denetleyicisi ile bir simülasyon yapmışlardır. Simülasyon sonuçları, önerilen çözümün tüketicinin konfor düzeyini arttırarak elektrik tüketim ücretlerini azaltma açısından verimli olduğunu göstermektedir.

Javale ve arkadaşları [16], Android aksesuar geliştirme kartı (ADK) kullanarak ev otomasyonu ve güvenlik sistemi geliştirmişlerdir. Geliştirilen tasarımın temeli, evden bağımsız bir yerleşik geliştirme kartı olan Android ADK'ya dayanmaktadır. Ev içerisindeki elektronik cihazlar ADK'ya bağlanmakta ve ADK ile Android mobil cihazlar veya tabletler arasında iletişim kurulmaktadır. Ev aletleri, gömülü sistem kartının giriş/çıkış portlarına bağlandıktan sonra ev aletlerinin durumları ADK'ya iletilmektedir. Yetkili kişinin ev aletlerine erişebilmesi için kimlik doğrulaması yapması gerekmektedir. Geliştirilen sistemin uygulamasında başarılı sonuçlar elde edilmiştir.

Pandya ve arkadaşları [17], ev sakinlerinin evdeki elektrikli aletlerin çalıştırılmasını sağlamak için akıllı telefon kullanan bir otomasyon sistemi geliştirmişlerdir. Sistemde üç bileşen bulunmaktadır; cihazları bağlamak için bir Arduino mikrodenetleyicisi, sinyal aktarımı için Bluetooth modülü ve akıllı telefonlarda çalışan bir Android uygulaması. Sistem ayrıca, sesli komut özelliğini de desteklemektedir. Sistem tasarımı bağımsız bir Arduino geliştirme kartı üzerine kurulmuş ve cihazlar bu karta röle modülleri kullanılarak bağlanmıştır. Akıllı telefon ile Arduino, Bluetooth modülü aracılığıyla etkileşime geçmektedir. Geliştiricilerin sistemi tasarlamadaki temel amacı, sistemin düşük maliyetli ve ölçeklenebilir olmasıdır.

Hisham ve arkadaşları [18], Android telefon kullanarak Bluetooth tabanlı bir ev otomasyon sistemi geliştirmişler ve sistemin düşük maliyetli bir prototipini ve uygulamasını sunmuşlardır. Sistemin temelinde Arduino Mega 2560-R3 kartı bulunmaktadır. Elektronik aygıtlar bu kartın giriş/çıkış portlarına röleler kullanılarak fiziksel olarak bağlanmıştır. BluetoothHome isimli Android uygulamasıyla ev aletlerinin uzaktan kontrolü için bir grafiksel kullanıcı arabirimi (GUI) geliştirilmiştir.

Potts ve Sukittanon [19], Android mobil cihazlarla yönetilebilen bir güvenlik sistemi geliştirmişlerdir. Mobil cihaz ve güvenlik sistemi, yalnızca kısa menzilli bir iletişim sistemi kullandığı için Bluetooth üzerinden iletişim kurmaktadır. Güvenlik sistemi, kurulu olduğu kapının durumunu, kilitleme, kilit açma veya kontrol etme komutlarını gerçekleştiren GUI ile mobil cihazdan hızlıca gönderebilmektedir. Güvenlik sistemi, daha sonra bu komutlara göre uygun işlemi yaparak mobil cihaza bir onay göndermekte ve aynı zamanda, güvenlik sistemi, kapının

açık olup olmadığını da kullanıcıya söyleyebilmektedir. Kapı, kullanıcının mobil cihazı kaybetmesi ihtimaline karşı geleneksel bir kilit ve anahtar içermektedir.

Garlapati ve arkadaşları [20], ev ile evdeki elektrikli aletleri Bluetooth ile birbirine bağlayan bir iletişim ağı tasarlamışlardır. Aynı zamanda akıllı evde bulunan güneş panelleri ile sistemin gücü sağlanabilmektedir. Çalışma, ev otomasyonu için çoklu kontrol sistemi uygulaması ve güvenlik teknolojileri içermektedir. Sistemde güneş paneli, güç kaynağı, kızılötesi sensör (IR), Bluetooth modülü, nem sensörü, sıvı kristal ekran (LCD), L293D motor sürücü entegresi ve buzzer kullanılmıştır. Sistemde otomatik ve manuel olmak üzere 2 temel mod mevcuttur. Otomatik modda, sıcaklık yükseldiği zaman fanlar devreye girmekte iken ışık odaya fazla girdiği zaman da lambalar söndürülür. Manuel modda ise, odanın ışıkları ve fan Bluetooth aracılığı ile Android telefonlardan kontrol edilmektedir.

2.2. Literatürde GSM Tabanlı Sistemler Üzerine Yapılmış Çalışmalar

GSM teknolojisi, Avrupa Telekomünikasyon Standartları Enstitüsü (ETSI) tarafından, cep telefonları için kullanılan ikinci nesil (2G) dijital hücreli ağların protokollerini tanımlamak için geliştirilen bir sistemdir. GSM, insan sesini bu tür teknoloji kullanan cep telefonları şebekelerine taşımak için kullanılır. Ayrıca GSM'in kısa mesaj servisi (SMS), uluslararası dolaşım, faks ve veri mesajlaşma servisi gibi birçok özelliği de vardır [21].

Kardaş ve Özerdem [22], GSM üzerinden haberleşen bir akıllı ev uygulaması geliştirmişlerdir. Sensörler aracılığıyla alınan verilerle evdeki durum bilgileri gözlenmekte ve röleler aracılığıyla da elektrikli donanımların kontrolü sağlanmaktadır. Geliştirilen sistemde, elektrikli donanımların kontrolü başarı ile sağlanmıştır.

Huang ve arkadaşları [23], kablosuz sensör ağları (WSN) ve GSM teknolojisi kullanarak düşük güç tüketimli bir ev güvenlik alarm sistemi geliştirmişlerdir. Sistem hırsızlık, gaz sızıntısı ve yangın gibi durumları algılayabilmekte ve ev sakinlerine uyarı SMS'i gönderebilmektedir. Sistemde GSM kontrol donanımı olarak SMENS TC35 GSM modülü kullanılmıştır. C51 dilinde geliştirilen yazılım ile veri toplama, telefonda kablosuz mesaj gönderme ve alma gibi işlemler başarıyla gerçekleştirilmiştir.

Can ve arkadaşları [24], ev sakinlerinin evde olmadığı dönemlerde elektrikli cihazların bozulmaları sonrası çıkabilecek sorunların önüne geçmeyi amaçlamışlardır. Sistemde LM35 sıcaklık sensörü, PIC16F877 mikro denetleyicisi ve SMS fonksiyonları için Siemens C55 cep telefonu kullanılmıştır. Yapılan çalışmada sistem, evlerdeki buzdolapları ve soğutucular için olası arıza durumunda ev sakinlerini uyarı SMS'i ile bilgilendirecek şekilde tasarlanmıştır. Ürün, ev tipi bir buzdolabında test edilmiş ve başarılı sonuçlar elde edilmiştir.

Ocak ve Gökrem [25], Arduino Uno R3 geliştirme kartı kullanarak bir güvenlik sisteminin prototipini hazırlamışlardır. Sistemin yazılımsal kontrolü C# programlama diliyle yapılmıştır. Tasarlanan güvenlik sisteminde ultrasonik mesafe sensörü, sıcaklık sensörü, ateş algılayıcı sensör ve gaz sensörü kullanılmıştır. Sistemde bulunan cep telefonu, güvenlikle ilgili bir acil durum olduğu zaman veri tabanında kayıtlı kullanıcılara uyarı SMS'i ve e-posta atabilmektedir. Sistem testleri sonucunda başarılı sonuçlar elde edilmiştir.

Teymourzadeh ve arkadaşları [26], ev cihazlarını kontrol etmek için GSM teknolojisi kullanmayı amaçlamıştır. Önerilen çalışmada ev sakinleri, SMS yoluyla ev içerisindeki elektrikli aletlerin herhangi birinin açık ya da kapalı olduğunu görebilmekte ve aynı zamanda elektrikli aletleri kontrol edebilmektedir. Geliştirilen sistemin prototipi yapılmış ve kontroller sonucunda başarılı sonuçlar alınmıştır.

Jivani [27], Android cep telefonları için App Inventor kullanarak GSM tabanlı güvenlik kontrol sistemi geliştirmiştir. App Inventor'da uygulama geliştirmek için kod yazılması gerekli değildir. Bunun yerine var olan kod bloklarını uygulamaların gerektirdiği oranda birleştirmek için basit bir ara yüz tasarımı vardır. App Inventor, programlamayı eğlenceli hale getirmek ve kodlama bilmeyenlerin bile uygulama geliştirebilmesini sağlamak için tasarlanmıştır. Çalışmada kullanılan donanım parçaları Arduino Uno, GSM modülü, röle ve akıllı telefondur. Elektrikli ev aletleri rölelere takılarak Arduino'nun giriş/çıkış dijital portlarına, sonrasında ise GSM modülü Arduino'ya bağlanmaktadır. App Inventor aracılığıyla geliştirilen Android uygulaması ile ev sakinleri SMS yoluyla sisteme bağlı röleleri istedikleri gibi kontrol edebilmektedir. Sistem çeşitli telefonlarda çalıştırılarak test edilmiş ve başarılı sonuçlar alınmıştır.

Hasan ve arkadaşları [28], GSM teknolojisine sahip mikrodenetleyici tabanlı bir ev güvenlik sistemi tasarımı ve uygulaması sunmuşlardır. Sistemde Bluetooth modülü, led, keypad, basınç sensörü, GSM modülü, LCD ekran, servo motor ve buzzer bulunmaktadır. Sistem, ev içerisinde herhangi bir güvenlik ihlali olması durumunda ev sakinlerini SMS ile uyaracak şekilde tasarlanmıştır. Aynı zamanda sistemi Bluetooth ile kontrol etmek de mümkündür. Çalışma, akıllı ev sistemleri için çok yönlü bir güvenlik sağlamaktadır.

Singh ve arkadaşları [29], çalışmalarında Android cep telefonları ile GSM tabanlı bir Android uygulaması kullanarak ev aletlerinin ve güvenlik sistemlerinin nasıl kontrol edileceğini göstermektedir. Sistemde ultrasonik mesafe sensörü, MQ2 ve MQ7 gaz sensörü, GSM modülü ve röle devreleri bulunmaktadır. GSM teknolojisini kullanmanın avantajı, dünyanın herhangi bir yerinden ev aletlerini izlemeyi ve kontrol etmeyi sağlamasıdır. Aynı zamanda sistem herhangi bir acil durumda kullanıcılara SMS atabilmektedir.

Rana ve arkadaşları [30], uygun maliyetli ve güçlü bir ev güvenlik sistemi geliştirmişlerdir. GSM teknolojisi kullanan sistem ev sakinleri için uzaktan kontrol imkânı da sunmaktadır. Sistem aynı zamanda zararlı gaz sızıntısının tespitini de yapmaktadır. Tüm işlemler

Android cep telefonu üzerinden takip edilebilmektedir. Sistemde röle modülleri, gaz sensörü, hareket sensörü ve GSM modülü bulunmaktadır. Ana kontrolcü olarak ATmega328 mikrodenetleyici kullanılmıştır. Geliştirilen sistem testler sonucunda başarılı bir performans elde etmiştir.

Choudhury ve arkadaşları [31], kullanıcılar için acil durumlarda yardım almayı sağlayan basit, hızlı ve güvenilir bir yol sunmaktadır. Sistemin kontrolü için bir mikrodenetleyici ve GSM teknolojisi kullanılmıştır. Proje 8 bitlik ATmega 16 mikrodenetleyicisi, SIM900A GSM modülü ve 2 Android uygulaması içermektedir. Uygulamalardan biri cihaz yapılandırma ayarlarını içermektedir. Panik düğmesine basıldığında, göndericinin küresel konumlama sistemi (GPS) bilgileri ve acil durum mesajı önceden tanımlanmış olan yerlere iletilmektedir. Geliştirilen cihaz mobil şebeke olan her yerde kullanılabilir. Geliştirilen cihaz mobil şebeke olan her yerde kullanılabilir.

Parab ve Joglekar [32], evleri hırsızlardan korumak için GSM tabanlı, kablosuz bir ev güvenlik sistemi geliştirmişlerdir. Tasarlanan sistemde, GSM modülü ve kapı alarmı ile tetiklenen bir röle bulunmaktadır. Sistem olası kötü niyetli birini tespit ettiğinde hızlı bir şekilde ev sahibini bilgilendiren bir SMS atmaktadır. Aynı zamanda mikrodenetleyici de önceden belirlenen mesajı ilgili yerlere çağrı ile haber vermektedir. Bu sistem mevcut teknolojiler üzerinde test edilmiş ve başarılı sonuçlar elde edilmiştir.

2.3. Literatürde İnternet Tabanlı Sistemler Üzerine Yapılmış Çalışmalar

Kablolu ve kablosuz ağ teknolojilerinin gelişmesiyle birlikte, akıllı telefonlar ve tabletler gibi internete bağlı mobil cihazlar artık yaygın olarak kullanılmaktadır [33]. Bununla birlikte, yeni geliştirilen kontrol ve güvenlik sistemleri küçük boyutları, kolay kullanımları ve düşük maliyetleri nedeniyle çok sık kullanılmaktadır. Böylece, yeni bir kavram olan IOT kullanılmaya başlanmıştır. IOT, birbirleriyle etkileşime girebilen küresel bir makine ve cihaz ağı olarak öngörülen yeni bir teknoloji paradigmasıdır [34]. IOT, gündelik hayatımızda kullandığımız cihazları internet üzerinden, insan müdahalesi olmadan kontrol etmeye yarayan sistemlere denir [35].

Bingol ve arkadaşları [36], Delta DVP28SV model programlanabilir lojik kontrolör (PLC) kullanarak internet tabanlı bir akıllı ev sistemi geliştirmişlerdir. Akıllı ev sistemi internete bağlı herhangi bir cihaz veya operatör tarafından kontrol edilebilmektedir. Geliştirilen akıllı ev içerisinde havalandırma, aydınlatma ve güvenlik sistemleri bulunmaktadır. Ev kullanıcıları için C# dilinde bir GUI hazırlanmıştır. Güvenlik sisteminde meydana gelen olağan dışı aktiviteler SMS ile kullanıcılara bildirilmektedir.

Kumar ve Lee [37], çalışmalarında ev aletlerinin kontrolü için Android tabanlı, kullanıcı ara birimi olan, düşük maliyetli bir akıllı yaşam sistemi sunmaktadır. Akıllı yaşam sisteminde bağlantı teknolojisi olarak Bluetooth ve internet kullanılmaktadır. Aynı zamanda ev içerisinde

güvenliği sağlamak için bir alarm sistemi de bulunmaktadır. Arduino mikrodenetleyicisi ev ortamındaki diğer sensörlerle iletişime geçebilmek için nRF24L01 radyo ve Arduino Ethernet modüllerini kullanmaktadır. Bluetooth modülü sistemdeki güvenlik ve gözetim (kapı kilit kontrolü, yangın algılama, alarm ve bildirimler), kimlik doğrulama, enerji yönetimi gibi işlemler için kullanılmıştır. Ayrıca sistem, aletleri kontrol edebilmek için sesli komut fonksiyonunu da desteklemektedir.

Baytürk ve arkadaşları [38], yerleşim alanlarına uzak konumlarda bulunan sera ortamlarının denetlenmesine olanak sağlayacak bir gömülü sistem tasarlamış ve internet tabanlı, düşük maliyetli bir sera otomasyon sistemi geliştirmişlerdir. Sistemde kullanılan sensörlerden alınan verilerin bir web sayfasına aktarılarak kullanıcılar tarafından izlenebilmesi sağlanmaktadır. Sistem sıcaklık, nem ve sulama sistemlerinin kontrolünü sağlayan sensörlerden oluşmaktadır. Sistemin internete bağlanabilmesi için OLIMEX-PIC WEB kontrol kartı kullanılmıştır. Çalışmada sunulan yöntem, sadece sera otomasyon sistemlerinde değil aynı zamanda uzaktan kontrol edilebilir tüm ortamlarda kullanılabilirliktedir.

Ramli ve arkadaşları [39], elektrikli cihazların kontrolü için web tabanlı bir sistem geliştirmişlerdir. Geliştirilen sistemin prototipi IDL-800 dijital laboratuvarında yapılmıştır ve web arayüzü olarak .NET teknolojisi kullanılmıştır. Çalışmada kullanılan metodoloji analiz, tasarım ve uygulama olmak üzere 3 aşamadan oluşmaktadır. Prototip ile elektrikli cihazlar başarıyla kontrol edilmiştir. Tasarlanan sistem aynı zamanda enerji tasarrufu ve güvenlik için de kullanılabilirliktedir.

Chandramohan ve arkadaşları [40], Android tabanlı akıllı telefon uygulaması kullanarak cihazları uzaktan kontrol edebilmek için internet protokolü (IP) bağlantılı bir mikrodenetleyici kullanan ev kontrol ve izleme sistemi tasarlamışlardır. Sistem çeşitli elektrikli cihazları Wi-Fi üzerinden internete bağladıktan sonra Android uygulaması üzerinden cihazların tek tek kontrolünü sağlamaktadır. Sistemde lambalar, fanlar, LM35 sıcaklık sensörü ve ışığa bağımlı direnç (LDR) sensörü bulunmaktadır. Burada LDR lamba kontrolünden, LM35 ise fanların kontrolünden sorumludur. Önerilen ev ve enerji kontrol sistemi, kullanıcılar için akıllı hizmetler ve enerji tasarrufu sağlamaktadır.

Khan ve Mouftah [41], ev içerisindeki ısıtma, havalandırma ve klima cihazlarını web servisler üzerinden tek bir merkezden yönetebilen bir yaklaşım önermişlerdir. Önerilen yaklaşımda, web servisi merkezi bir bilgisayarda çalışmaktadır. Ara katman yazılımı veya ek denetleyici bulunmamaktadır. Merkezi bir bilgisayar doğrudan akıllı ev elemanları ile iletişim kurmaktadır. Kullanıcı, akıllı evle web üzerinden etkileşime geçebilmekte ve sıcaklık gibi bazı değerleri kontrol edebilmektedir. Böylece düşük maliyetli, kolay kullanılabilen, güvenli bir sistem tasarlanmıştır.

Yüzgeç ve Aba [42], yaşlı ve engelli insanların evdeki yaşamlarını kolaylaştıracak bir akıllı ev uygulaması gerçekleştirmişlerdir. Anahtarsız giriş, gaz kaçağı, su baskını ve yangın kontrolleri, garaja otomatik giriş, otomatik aydınlatma, deprem durumu ve iklimlendirme gibi senaryolar çalışmada kullanılmıştır. Çalışmada donanım altyapısı olarak RPi kullanılmıştır. Akıllı ev uygulamasının testleri için bir prototip ve yönetimi için de web sayfası tasarlanmıştır. Donanımlar ve yazılım prototip ev sisteminde test edilmiş ve başarılı sonuçlar alınmıştır.

2.4. Literatürde ZigBee Tabanlı Sistemler Üzerine Yapılmış Çalışmalar

ZigBee teknolojisi, kablosuz sensör ağlarında en yaygın olarak kullanılan veri iletişim standartlarından biridir. ZigBee, yüzlerce üyesi olan ZigBee topluluğu tarafından üretilmiştir. Ağ protokolü olarak Elektrik ve Elektronik Mühendisleri Enstitüsü (IEEE) 802.15.4'ü kullanır [43]. IEEE 802.15.4 ve ZigBee arasındaki ilişki, IEEE 802.11 ve Wi-Fi ile aynıdır [44]. ZigBee teknolojisinin kullanıldığı güncel uygulama alanları; ev otomasyonları, ZigBee akıllı enerji, telekomünikasyon uygulamaları ve kişisel evlerdir.

Hou ve arkadaşları [45], gerçek zamanlı ev güvenliğinin sağlanması için ZigBee teknolojisi kullanmışlardır. Donanım altyapısında, CC2430 ZigBee modülü bulunmaktadır. Geliştirilen sistem, anormal durumlarda kullanıcılara SMS ve çoklu ortam mesajlaşma servisi (MMS) gönderebilmekte ve uzaktan ev aletlerini kontrol edebilmektedir. Yapılan testlerde, sistemin yüksek düzeyde güvenlik sağladığı görülmüştür.

Liu [46], ZigBee teknolojisini kullanarak GSM ve genel paket radyo servisi (GPRS) ağına dayalı akıllı ev sistemi tasarlamıştır. Sistem CC2430 ZigBee modülü kullanarak sıcaklık ve nem değerlerini kontrol etmektedir. Aynı zamanda sistemde, duman, gaz, yangın sensörleri ve hırsız alarmı bulunmaktadır. Çalışma, yeni tip akıllı ev sistemleri için uygun bir yöntem sunmaktadır.

Liang ve arkadaşları [47], PIC18LF4620 mikrodenetleyicisi kullanarak ZigBee tabanlı bir akıllı ev sensör ağı sistemi önermektedir. Sistemin uzun mesafeli kontrolü için genel aktarmalı telefon şebekesi (PSTN) ve yakın mesafeli kontrol için ZigBee teknolojisi kullanılmaktadır. Sistem, elektrikli ev aletlerinin ve evin sıcaklık değerlerinin uzaktan kontrolünü sağlamaktadır. Yapılan testler sonucunda geliştirilen sistemin akıllı ev sistemleri için güçlü ve düşük maliyetli bir çözüm sunduğu gözlemlenmiştir.

Dagtas ve arkadaşları [48], ZigBee teknolojisi kullanan akıllı bir evde kablosuz sağlık izleme sistemi geliştirmişlerdir. Hayati sinyaller, 3 katmanlı bir mimari kullanılarak toplanıp işlenmektedir. İlk katmanda çeşitli kablolu ve kablosuz problemleri çalıştıran gövdede taşınan bir mobil cihaz bulunmakta iken ikinci katmanda mobil cihaz tarafından iletilen verileri depolayan bir sunucu cihaz bulunmaktadır. Son katmanda ise veriler uzmanlar tarafından incelendikten

sonra servis sağlayıcı merkezine iletilmektedir. Böylece herhangi bir hayati risk durumunda bazı tedbirler önceden alınabilmektedir.

Krishna ve Nagendram [49] çalışmalarında, yalnız yaşayanlar, yaşlılar ve engelliler için kablosuz ev otomasyon sistemini tanıtmışlardır. Otomasyon sisteminde ses komutlarının tanınmasında ucuz ve düşük güç tüketen ZigBee modülü kullanılmaktadır. Ev otomasyon sistemi, sesli komutları kullanarak evdeki tüm ışıkları ve elektrikli aletleri kontrol etmek için tasarlanmıştır. ZigBee modülü, ses verilerini alır ve bu verileri ARM9 kontrol ünitesine iletir. ARM9 kontrol ünitesi, alınan verileri işleyerek tekrar ZigBee modülüne gönderir. Daha sonra ZigBee modülü, bağlı olduğu cihaza komut göndererek cihazın istenilen şekilde çalışmasını sağlar. Konuşma tanıma işlemi Microsoft konuşma API'leri ile gerçekleştirilmiştir. Yapılan testlerde, başarılı ve umut verici sonuçlar alınmıştır.

Al-Ali ve arkadaşları [50], akıllı evlerin bahçelerinde kullanılabilen bir sulama sistemi geliştirmişlerdir. Mevcut akıllı ev ile entegre çalışan sistem toprak sıcaklık ve nem sensörü, su vanası, ZigBee modülü ve bir mikrodenetleyiciden oluşmaktadır. Ana sistem bir dizi kuralla dayanarak çimleri ve ağaçları sulamak için bulanık mantık sulama algoritması kullanmaktadır. Ev sakinleri bahçedeki çim ve ağaçları internet üzerinden yerel ve uzaktan kumandayla manuel veya otomatik olarak sulayabilmektedirler. Önerilen sistem, yapılan testler sonucunda başarılı sonuçlar elde etmiştir. Sistem çok az değişikliklerle diğer ev otomasyon sistemlerine entegre edilebilmektedir.

Kim ve arkadaşları [51], mevcut akıllı sistemlerde kullanılan kontrol ağlarının performanslarını arttırmak için ZigBee teknolojisini kullanmışlardır. Çalışmada ele alınan akıllı ev sistemi, temel bağlantı olarak 3G ve ZigBee kablosuz ağ teknolojilerinin gerçek zamanlı kontrolünü içermektedir. Geleneksel akıllı evlerde kullanılan televizyon, buzdolabı ve klima gibi elektrikli ev aletlerinin kontrolü ZigBee teknolojisi ile birleştirilip bir sistem oluşturulmuştur. Geliştiriciler, her eve kolayca entegre edilebilen bu sistem ile yaşam kalitesini arttırmayı amaçlamışlardır.

Siddiqui ve arkadaşları [52], sokak lambaları için kullanıcı merkezli ve enerji tasarruflu bir aydınlatma kontrol mimarisi geliştirmişlerdir. Sistem kullanıcısı sokak lambalarını ZigBee kablosuz ağ teknolojisi ile birleştirmekte ve gerekli bilgileri internet üzerinden ilgili kişilere göndermektedir. Sistemde, lambaların uzaktan izlenebilmesi ve kontrol edilebilmesi için bir kontrol yazılımı bulunmaktadır. Geliştirilen sistem üniversite içinde kurulmuş ve test edilmiştir. Testler sonucunda başarılı sonuçlar elde edilmiştir.

Malhi ve arkadaşları [53], ZigBee tabanlı fizyolojik parametreleri izlemek için giyilebilir bir cihaz tasarımı gerçekleştirmişlerdir. Sistem kişinin bileğine takılarak vücut sıcaklığı ve kalp hızı gibi fizyolojik parametrelerini izlemek için kullanılabilir. Farklı yaşamsal belirtileri ölçmek için birkaç sensör ve kişinin düşmesini algılamak için bir darbe sensörü kullanılmıştır.

Cihaz, kişinin tıbbi olarak rahatsız olup olmadığını tespit etmekte ve bilgisayara bağlı bir alıcı üniteye alarm sinyalleri göndermektedir. Bu alarm sinyalleri gerektiğinde kişiye yardım gönderilmesini sağlamaktadır. Cihaz sporcuları ve bebekleri izlemek için de kullanılabilir. Cihazın bir prototipi üretilmiş ve gerçekleştirilen testlerde başarılı sonuçlar alınmıştır.

Leccese ve arkadaşları [54], akıllı bir şehir uygulaması geliştirmişlerdir. Geliştirilen akıllı şehir uygulaması, yeni teknolojilere dayalı ve tamamen uzaktan kumandalı bir sistemdir. Her elektrik direğinin yönetimi için birer elektronik kart kullanılmaktadır. ZigBee teknolojisi ile tüm elektrik direkleri birbirlerine bağlanmakta ve sonrasında elektrik direklerinden alınan bilgiler RPi tabanlı bir merkezi işlem birimine iletilmektedir. Geliştirilen akıllı şebeke aynı zamanda WiMAX bağlantısı ile uzaktan kontrol edilebilmektedir. Test edilen sistemde başarılı sonuçlar elde edilmiştir.

2.5. Literatürde RFID Tabanlı Sistemler Üzerine Yapılmış Çalışmalar

RFID teknolojisi, bir nesneye fiziksel bir etiket yerleştirme yöntemiyle radyo dalgaları kullanarak bir kimlik numarası depolayabilme şeklidir. RFID, verimliliği ve güvenliği arttıran, hataları önleyen, maliyetleri düşüren bir teknolojidir [55]. RFID teknolojisi ilk olarak, 1945 yılında Sovyetler Birliği için radyo dalgalarını sesli bilgilerle yeniden ileten bir casus aracı olarak ortaya çıkmıştır [56]. RFID teknolojisi araç takip, otomatik stok yönetimi, hayvan takip, güvenli mağaza kontrolleri, tedarik zinciri yönetimi, otomatik ödeme vb. alanlarda kendine geniş yer edinmiştir [57].

Ali ve Sonkusare [58], RFID tabanlı akıllı alışveriş ve faturalandırma konusunda yenilikçi bir yaklaşım geliştirmişlerdir. Çalışmanın temel amacı, kişisel alışverişe yardımcı olmak için teknolojik odaklı, düşük maliyetli, kolay ölçeklenebilir ve sağlam bir sistem sunmaktır. Geliştirilen sistem; kart konum tespit ünitesi, sunucu haberleşme ünitesi, kullanıcı arabirimi ve gösterge ünitesi, fatura ve envanter yönetim ünitesinden oluşmaktadır. Bu üniteler akıllı ve kapalı bir sisteme entegre edilmiştir. Geliştirilen akıllı alışveriş sepeti sayesinde ödeme kuyukları kısılacak, insanların alışverişlerde harcadıkları zaman azalacaktır. Geliştirilen prototip modeli ile başarılı sonuçlar elde edilmiştir.

Mainetti ve arkadaşları [59], ultra yüksek frekans (UHF), RFID ve IEEE 802.15.4 WSN teknolojilerini kullanarak akıllı park sistemi geliştirmişlerdir. Geliştirilen sistem, park yerlerinin doluluk durumu hakkında bilgi toplayabilmekte ve özelleştirilmiş bir yazılım uygulaması kullanarak sürücülerini en yakın boş park yerine yönlendirebilmektedir. Uygulama aynı zamanda kullanıcıların otopark ücretlerini ödemesini sağlamak için NFC tabanlı bir e-cüzdan sistemi de kullanılmaktadır. Ayrıca Java Restful ve Google Cloud Messaging (GCM) teknolojileri kullanan bir

yazılım uygulaması alarm olaylarını yönetmek amacıyla merkezi bir sunucuya kurulmuştur. Sistemin bir prototipi geliştirilerek başarılı sonuçlar alınmıştır.

Yao ve arkadaşları [60], RFID teknolojisini kullanarak sağlık hizmetlerinde hasta tanımlama, izleme ve hasta-ilaç uyumu gibi çeşitli uygulamaları desteklemek için bir sistem geliştirmişlerdir. Bununla birlikte, büyük miktarda RFID verisinin yönetimi ve bunların tıbbi bağlamda anlaşılması bazı zorlukları da ortaya çıkarmıştır. Bu zorlukları ortadan kaldırmak için etkili bir çözüm olan içeriğe duyarlı uygulamalar için anlamlı olaylar çıkarabilen karmaşık olay istemcisi (CEP) geliştirilmiştir. CEP sistemi aynı zamanda, bir hastanedeki cerrahi olayları ve kritik uygulamaları modellemek için de kullanılmaktadır. Çalışmanın prototipi geliştirilerek bir hastanede uygulanmış ve gereken testler yapılmıştır. Test sonuçları, işlem gecikmesi ve tespit doğruluğu açısından performans değerlendirmesinin kabul edilebilir olduğunu göstermektedir.

2.6. Literatürde Yapay Zekâ Tabanlı Sistemler Üzerine Yapılmış Çalışmalar

Yapay zekâ, ismi resmi olarak ilk defa 1956 yılında "Dartmouth College Artificial Intellegent" konferansında John McCarty tarafından ortaya atılmıştır. İlk yapay zekâ laboratuvarı ise 1959 yılında John McCarty ve Marvin Minsky tarafından kurulmuştur [61]. Yapay zekânın birçok alt alanı vardır. Bunlardan en popülerleri; yapay sinir ağları (YSA), fuzzy-logic, uzman sistemler, makine öğrenmesi ve derin öğrenmedir.

Hussein ve arkadaşları [62], engelli insanlar için yapay zekâ tabanlı bir akıllı ev tasarımı yapmışlardır. Sistem genel olarak iki omurgadan oluşmaktadır. Birincisi ana ağ, ikincisi ise ana ağın bir yedeği olarak çalışmaktadır. Bu ağların amacı tüm sistemin farklı unsurlarını birbirine bağlamaktır. Sistemde uyarlanabilir öğrenme için iki YSA vardır. Bu ağlar bir etkinliğin olasılığını tahmin etmekten sorumludur. Böylece sistem kullanıcının ihtiyaçlarına göre uyarlanabilmektedir. Tasarlanan akıllı ev sistemi evi kullanan kişinin engel durumuna göre değiştirilebilmektedir.

Pathak ve arkadaşları [63], akıllı şebekelerde konut yükünün talep tepki yönetimi için yapay zekâ tabanlı bir sistem geliştirmişlerdir. Yapay zekâ yöntemi olarak parçacık sürü optimizasyonu (PSO) kullanılmıştır. Önerilen metodoloji güç tüketiminin belirli bir seviyeyi aşması durumunda yük tüketimini yönetmektedir. Yük tüketimi, tüketicilerin tercihlerini de dikkate almaktadır. Geliştirilen sistemin kullanımı sonucunda yıllık olarak önemli miktarda tasarruf yapıldığı gözlemlenmiştir.

Basnayake ve arkadaşları [64], yapay zekâ tabanlı bir akıllı bina otomasyon kontrol cihazı (AIBSBAC) geliştirmişlerdir. Sistem gelişmiş kullanıcı konforu, güvenlik, gelişmiş enerji performansı ve kullanıcı tercihlerine kolayca adapte olma gibi avantajlar sunmaktadır. AIBSBAC'ın tasarımı akıllı kullanıcı kimliği sistemi, iç ve dış ortam gözleme sistemi, akıllı karar

verme sistemi ve aynı zamanda evrensel bir kızılötesi iletişim sisteminden oluşmaktadır. Sistemin donanımsal altyapısında Arduino Mega, RF cihazı, sıcaklık ve nem sensörü, ışık sensörü, hareket sensörü, Bluetooth modülü, RPi model B, IR sensörü ve çeşitli elektronik bileşenler bulunmaktadır. AIBSBAC'ın otomasyonu akıllı kullanıcı tanımlamaları, kullanıcı konforunun iyileştirilmesi ve maksimum enerji tasarrufu sağlamak için tasarlanmıştır. Çalışmanın sonucunda başarılı sonuçlar elde edilmiştir.

Chamoso ve Prieta [65], şehirlerin tüm unsurlarını birbirine bağlamak için çözümler üreten akıllı bir mimari önermişlerdir. Çalışma, şehirlerde trafiğin düzenlenmesi ve optimize edilmesi sorununa odaklı bir çözüm sunmaktadır. Tasarlanan sistem dört katmandan oluşmaktadır. İlk katman, kendinden sonraki katmanlara hizmet etmek için kullanılan iletişim standartları aracılığıyla farklı protokollerden veri almaktan sorumludur. İkinci katman, ilk katmandan alınan tüm verileri ortak bir protokole çevirir. Bu nedenle, bu seviyede sensör verilerini üst katmanlara düzgün bir biçimde iletebilmek için telemetri mesajlaşma protokolü (MQTT) kullanılmıştır. Üçüncü katman, doğrudan önceki katmana etki etmekte ve gerekli bilgiye karşılık gelen hizmetleri elde etmektedir. Dördüncü ve son katmanda ise sistemi izlemeleri ve kontrol etmeleri için son kullanıcılara bir dizi üst düzey hizmet sunulmaktadır. Sistem durumuna web servisleri aracılığıyla erişilebilmektedir. Sonuç olarak, kullanılan teknolojiden bağımsız olarak akıllı şehirlerin ihtiyaç duyabileceği her türlü sensörü birlikte veya bağımsız olarak ele alabilen ölçeklenebilir bir mimari oluşturulmuştur.

Güneş [66], doktora tez çalışmasında, öğrenebilen, web tabanlı, düşük enerji tüketimli ve modüler ev otomasyon sistemi geliştirmiştir. Temel donanım olarak RPi ve Arduino Mega kullanılmıştır. Akıllı ev içerisindeki kontrolleri sağlamak için bir web ara yüzü geliştirilmiştir. Geliştirilen akıllı ev sisteminin kullanıcı davranışlarını öğrenerek hareket edebilmesi için yapay zekâ yöntemleri kullanılmıştır. Çalışmada, yapay zekâ algoritması olarak Markov modeli ile karınca koloni algoritmalarından esinlenerek bir algoritma geliştirilmiştir. Ancak geliştirilen bu hibrit algoritma ile ilgili yeterince bilgi verilmemiştir. Ayrıca kullanılan yapay zekâ yönteminin matematiksel olarak başarı oranlarına ve algoritmanın hata kriterlerine çalışmada yer verilmemiştir.

3. MATERYAL ve YÖNTEM

3.1. Problemin Tanımı

Akıllı ev sistemleri, ilk olarak 1980'li yıllarda Japonya ve birkaç ülkede ısıtma ve ışıklandırma sistemlerinin otomatiğe geçmesi ile ortaya çıkmıştır. Daha sonra uzaktan haberleşme ve güvenlik sistemlerinin de gelişmesiyle birlikte tam otomatik hâle gelmiştir [67]. Günümüzde akıllı ev sistemleri ile ilgili birçok çalışma yapılmaktadır. Bu çalışmalar büyük ölçüde güvenlik sistemleri ve kontrol sistemleri üzerinedir. Büyük teknoloji şirketleri de bu alana büyük yatırımlar yapmaktadır. Google, Amazon, Samsung, IBM, Microsoft vb. şirketler akıllı ev kontrol sistemleri için çeşitli ürünler geliştirmişlerdir. Büyük şirketlerin bu alana önem vermesi ve yatırım yapması, gelecekte akıllı ev kavramının daha çok gelişebileceği ve farklı teknolojilerle entegre edilebileceğini göstermektedir. Akıllı ev sistemleri sadece konfor, güvenlik ve tasarruf amacıyla kullanılmamaktadır. Engelli, yaşlı ve bakıma muhtaç birçok insanın ev içerisindeki hayatını kolaylaştırabilmek ve onları olası tehlikelerden korumak amacıyla da kullanılmaktadır.

Bu tez çalışmasında, RPi, Arduino ve çeşitli sensörlerle çalışan yapay zekâ tabanlı bir akıllı ev sistemi geliştirilmiştir. Çalışmanın amacı sıradan uzaktan kontrol edilebilen akıllı ev sistemlerinin yanı sıra sürekli kendini geliştiren ve öğrenebilen bir sistem tasarlamaktır. Öncelikle sistemin hafızasını oluşturan veri kümesinin belirli bir doygunluğa ulaşması gerekmektedir. Hafıza belirli bir doygunluğa ulaştığı zaman, sistem bazı aktiviteleri kullanıcı yararına otonom olarak gerçekleştirmektedir.

Geliştirilen sistemde 2 temel protokol vardır. İlk protokolda ev sakinleri evdeyken yapay zekâ algoritması, kontrol sistemi ve temel güvenlik sistemi çalışmaktadır. Geliştirilen yapay zekâ algoritması kullanıcıların ev içerisindeki rutin aktivitelerini tahmin ederek bazı işlemleri kullanıcı yararına yapmaktadır. Bu sistem, ev sakinlerine daha konforlu bir yaşam sunarken aynı zamanda insan kaynaklı olası felaketleri de önlemektedir. Ev içerisinde kullanılan sensörlerden belirli zaman aralıklarında alınan veriler veri kümesine eklenerek zaman içerisinde ev sistemi daha akıllı hâle getirilmektedir. Böylece sistem, çok sık tekrarlanan aktivitelerin yanı sıra değişen aktiviteleri de algılayabilmektedir. Ev sakinleri evde iken ev içerisindeki belirli elektronik eşyaları Bluetooth üzerinden Android telefon ile kontrol edebilmekte ve Android uygulaması üzerinden sıcaklık değerlerini anlık olarak görebilmektedir. Temel güvenlik sisteminde ise yanıcı gaz alarmı, yangın alarmı ve su baskını algılayıcı çalışmaktadır. Sistem herhangi bir alarm durumu algıladığında ev sakinlerine uyarı SMS'i göndermekte ve alarmın algılandığı şebekeyi belirli bir süre kapatmaktadır. Böylece olası felaketlerin önüne geçilmektedir.

İkinci protokolda ise evde herhangi bir ev sakini olmadığı zaman ileri güvenlik ve uzak kontrol sistemleri devreye girmektedir. İleri güvenlik sisteminde yanıcı gaz alarmı, yangın alarmı,

su baskını algılama alarmı, hareket algılayıcı ile kameradan görüntü alma sistemi, ses alarmı ve kapı alarmı bulunmaktadır. Sistem herhangi bir alarm durumunda ev sakinlerine uyarı SMS'i göndermektedir. Aynı zamanda ev sakinleri uzaktan kontrol ile web sayfasından anlık olarak sıcaklık ve nem değerlerini, sistemdeki alarm durumlarını, kontrol panelini ve kamera takip sayfasını görebilmektedir.

3.2. Materyaller

3.2.1. Veri Kümesi

Veri kümesi, akıllı ev içerisindeki sensörlerden alınan değerlere tarih, gün ve saat bilgisi eklenerek oluşturulmuştur. Veri kümesinden bir kesit Tablo 3.1'de verilmiştir.

Tablo 3.1. Veri kümesi.


A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	R	S
1.08.2019	per	00:00	1	20	48	25	64	32	0	0	0	0	0	0	1	1	0
1.08.2019	per	00:30	1	20	48	25	65	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	01:00	1	20	48	25	67	32	0	0	0	0	0	0	1	1	0
1.08.2019	per	01:30	1	21	48	25	67	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	02:00	1	20	49	25	67	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	02:30	1	20	49	25	68	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	03:00	1	21	49	25	68	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	03:30	1	20	49	24	68	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	04:00	1	20	49	24	69	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	04:30	1	20	49	24	70	35	0	0	0	0	0	0	1	1	0
1.08.2019	per	05:00	1	20	50	24	71	32	0	0	0	0	0	0	1	1	0
1.08.2019	per	05:30	1	20	50	24	72	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	06:00	1	20	50	24	72	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	06:30	1	20	50	25	74	30	0	0	0	0	0	0	1	1	0
1.08.2019	per	07:00	1	20	50	25	71	36	0	1	0	0	0	0	1	1	0

Veri kümesi 18 nitelik ve 17.531 satır veriden oluşmaktadır. Veri kümesi akıllı evde bulunan hareket sensörü (PIR), ev sıcaklık ve nem sensörü (DHT11), ev dışı sıcaklık ve nem sensörü (DHT11), gaz sensörü (MQ5), alev sensörü, ses sensörü, röleler, lambalar, fan ve servo motor bileşenlerinden anlık olarak alınan sensör ve durum değerlerine göre oluşturulmuştur. Veri kümesinde A, B, C, E, F, G, H, I nitelikleri haricindeki nitelikler 0 ve 1'lerden oluşmaktadır. Veri kümesi içeriği Tablo 3.2'de verilmiştir.


Tablo 3.2. Veri kümesi içeriği.

Nitelik	Açıklama
Tarih (A)	Anlık olarak alınan tarih değeri (G/A/Y)
Gün (B)	Haftanın günleri
Saat (C)	Veri kümesine eklenen satırın saat değeri
EvdeOlma(D)	Ev sakinlerinin evde olma durumu (0-1)
EvSıcaklık (E)	Ev içerisindeki anlık sıcaklık değeri (°C)
EvNem (F)	Ev içerisindeki anlık nem değeri (%)
DışSıcaklık (G)	Ev dışındaki anlık sıcaklık değeri (°C)
DışNem (H)	Ev dışındaki anlık nem değeri (%)
Gaz (I)	Ev içerisindeki yanıcı gaz değeri (LPG ve Propan Gazı)
Yangın (J)	Ev içerisindeki yangın durumu (0-1)
Ses (K)	Ev içerisindeki ses değeri (0-1)
SalonIşık (L)	Salon lambasının durumu (0-1)
YatakOdasıIşık (M)	Yatak odası lambasının durumu (0-1)
Röle-1(N)	Röle-1'in durumu (0-1)
Röle-2 (O)	Röle-2'nin durumu (0-1)
Klima (P)	Klima durumu (0-1)
Perde (R)	Perde durumu (0-1)
Uyarı (S)	Evdeki anlık alarm durumu (0-1)

Sistem standart olarak her yarım saatte bir tüm sensörlerden aldığı değerleri tarih, gün ve saat bilgisiyle birlikte veri kümesine eklemektedir. Veri kümesi oluşturulduktan sonra kullanacağımız sınıflandırma algoritmalarından daha başarılı sonuçlar elde etmek için veri kümesine veri ön işleme yapılmıştır. Veri ön işlemede ilk önce sensör dalgalanmalarından dolayı eklenen hatalı veriler veri kümesinden çıkarılmıştır. Veri kümesindeki sıcaklık, nem ve gaz değerleri hariç diğer niteliklerimiz 0 ve 1 değerlerine sahiptir. Bu nedenle sadece sıcaklık, nem ve gaz nitelikleri için normalizasyon işlemi yapılmıştır. Veri kümesi sınıflandırma algoritmalarına tâbi tutulmadan önce 10 katlı çapraz doğrulama (10 fold cross validation) işlemi yapılmıştır. Çapraz doğrulama, mevcut veri kümesini eğitim ve test örnekleri olarak ayıran bir tekniktir. Veri kümesi k eşit parçaya ayrıldıktan sonra algoritma, k-1 parça ile eğitilmektedir. Daha sonra algoritma geriye kalan parça ile test edilmektedir [68]. Veri kümesindeki niteliklerin görsel grafikleri Şekil 3.1, 3.2'de gösterilmiştir.

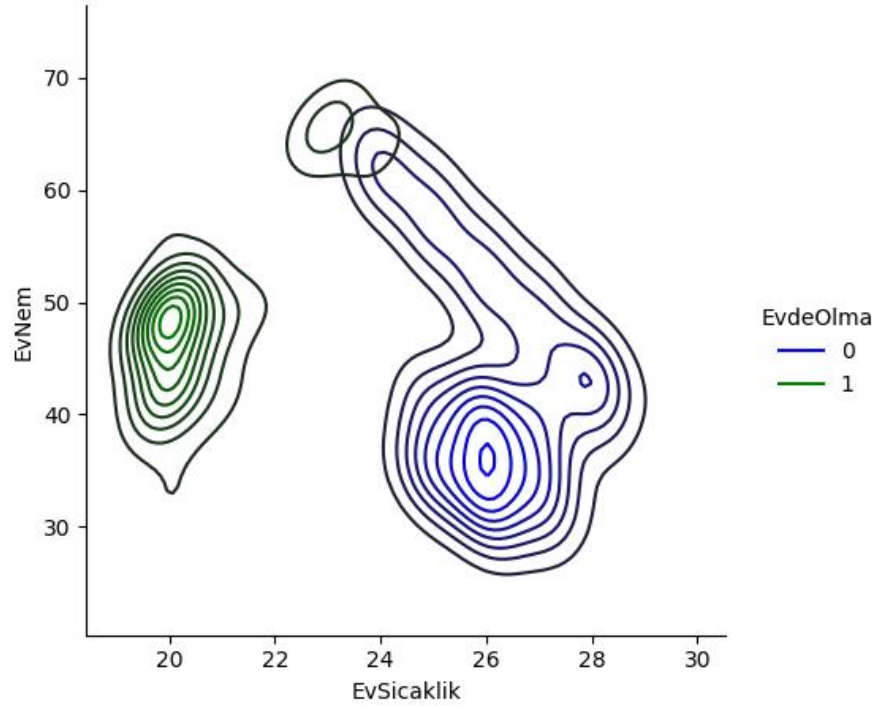


Şekil 3.1. Veri kümesinin görselleştirmesi -1.

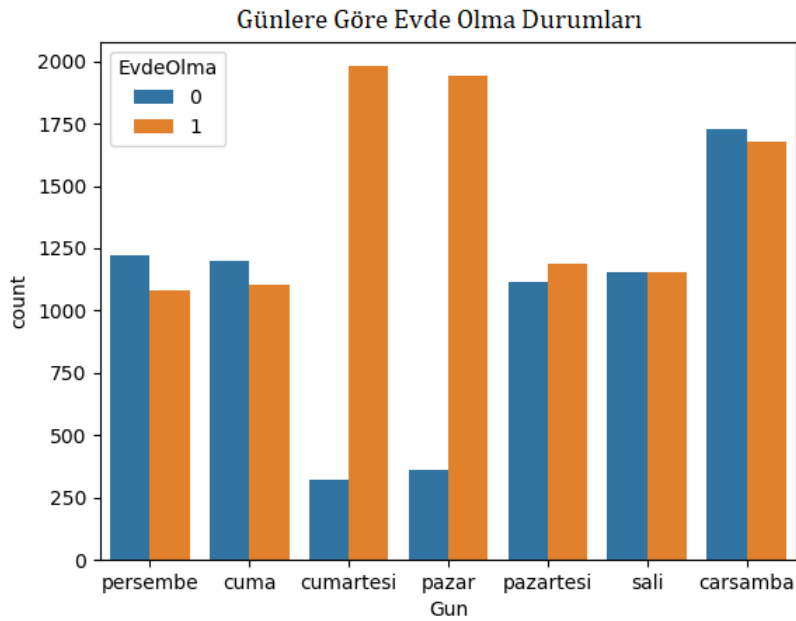


Şekil 3.2. Veri kümesinin görselleştirmesi -2.

Şekil 3.3'te ev sakinlerinin evde olup olmama durumlarına göre ev içerisindeki sıcaklık ve nem değerleri gösterilmiştir. Grafik değerleri yaz aylarında elde edildiği için ev sakinleri evdeyken evin sıcaklığında düşüş görülmektedir. Şekil 3.4'te görsel olarak haftanın günlerine göre ev sakinlerinin evde olma durumları gösterilmiştir. Grafığe göre düzenli bir iş hayatına sahip olan ev sakinlerinin hafta sonlarını genelde evde geçirmeyi tercih ettikleri görülmektedir.



Şekil 3.3. Evde olma durumuna göre sıcaklık ve nem değerleri.



Şekil 3.4. Günlere göre evde olma durumları.


3.2.2. Donanım

3.2.2.1. Mikrodenetleyici Kartları

Çalışmada mikrodenetleyici kartı olarak RPi ve Arduino kullanılmakta ve bütün sensörler ve komponentler RPi ve Arduino tarafından kontrol edilmektedir. RPi ve Arduino Nano kartlarının özellikleri Tablo 3.3 ve 3.4'te verilmiştir.

Arduino mikrodenetleyici kartı, elektronik devrelerin yapımında ve programlanmasında kullanılan açık kaynaklı bir geliştirme platformudur [69]. Arduino kartlarının temelinde bir adet Atmel AVR mikrodenetleyici bulunur. Arduino mikrodenetleyici kartlarının birbirinden farklı özelliklere sahip olan birçok modeli mevcuttur. Yapılacak olan projenin ihtiyacına göre farklı modeller kullanılabilir. Arduino, yazılımları ücretsiz olarak indirilebilmekte ve hazır kütüphaneleri sayesinde kolaylıkla programlanabilmektedir. Analog ve dijital giriş/çıkışları ile çeşitli sensörler kullanılarak dış dünya ile etkileşime geçebilir. Arduino ile insansız hava araçları, akıllı ev sistemleri, güvenlik sistemleri, labirent çözen araçlar gibi birçok proje gerçekleştirilebilmektedir.

Bu tez çalışması kapsamında kullanılan kart modeli Arduino Nano'dur. Arduino Nano görseli Şekil 3.5'te, özellikleri ise Tablo 3.3'te gösterilmiştir. Çalışmada Arduino Nano kullanılmasıdaki temel amaç, düşük güç tüketimi sağlaması ve küçük boyutlu olmasıdır.



Şekil 3.5. Arduino Nano mikrodenetleyici kartı [70].

Tablo 3.3. Arduino Nano özellikleri [70].

Arduino Nano	Özellik
Mikrodenetleyici	ATmega 328
Mimari	AVR
Çalışma Gerilimi	5 V
Flash Bellek	32 KB
SRAM	2 KB
Saat Hızı	16 MHz
Analog Giriş Pinleri	8 Adet
EEPROM	1 KB
Giriş/Çıkış Pinleri Başına DC Akım	40 mA
Giriş Gerilimi	7-12 V
Dijital Giriş/Çıkış Pinleri	22 Adet (6 tanesi PWM)
PWM Çıkışı	6 Adet
Güç Tüketimi	19 mA
Pcb Boyutu	18 x 45 mm
Ağırlık	7 gr

RPi, 2009 yılında İngiltere’de Raspberry PI Vakfı tarafından geliştirilen kredi kartı boyutunda düşük maliyetli, küçük ve taşınabilir bir bilgisayardır. RPi’ye klavye, fare ve ekran bağlandığında bir bilgisayardan farksızdır [71]. RPi’nin farklı özelliklere sahip birçok modeli mevcuttur. RPi ile web sunucusu, robotik projeleri, oyun konsolu, akıllı sistemler, medya oynatıcısı gibi birçok proje yapılabilir. RPi için tasarlanan resmi işletim sistemi Raspbian OS’dur. Raspbian OS programlama odaklı kolay kullanım deneyimi sunan bir işletim sistemidir.

Bu çalışmada kullanılan model, RPi 3 Model B+’dır. Modelin görseli Şekil 3.6’da, özellikleri ise Tablo 3.4’te verilmiştir.

**Şekil 3.6.** RPi 3 Model B+ [72].

Tablo 3.4. RPi 3 Model B+ özellikleri[72].

RPi 3 Model B+	Özellik
İşlemci	Broadcom BCM-2837B0, Cortex-A53/AMRv8 Quad-Core 64-bit SoC @ 1.4GHz
Ram	1 GB LPDDR2 SDRAM
Wireless LAN	Çift Bant 2.4 + 5 GHz 802.11.b/g/n/ac
Ethernet	300Mbps Gigabit, PoE HAT Uyumlu
Bluetooth	2, Düşük Enerji
GPIO	40 Pinli Header, Güç Giriş Pinleri
Hafıza	Micro SD Kart Girişi
Video	HDMI, DSI Ekran Portu + CSI Kamera Portu
Ses	4 Kutuplu 3.5 mm ses + Kompozit Video Portu
USB	4 Adet USB 2.0 + MikroUSB 5 V/2,5 A Güç Girişi
Multimedya	H.264, MPEG-4 decode (1080p@30), H.264 encode (1080p@30), OpenGL ES 1.1, 2.0 Grafik
Çevre Şartları	Çalışma Sıcaklığı 0 - 50 °C
Üretim Desteği	Ocak 2023'e kadar üretim desteği

Bu çalışmada kullanılan ana mikrodenetleyici RPi'dir. Arduino Nano, RPi'ye USB kablusuyla bağlanarak yardımcı mikrodenetleyici kartı olarak kullanılmıştır. Çalışmada RPi ile Arduino Nano seri haberleşme ile iletişim kurmakta ve birbirleri arasında veri alışverişi yapabilmektedirler. Tezde iki mikrodenetleyici kullanılmasındaki amaç iki geliştirme kartının da birbirlerinden farklı iyi özelliklerinden faydalanabilmektir. RPi'de dâhili wireless, Bluetooth ve ethernet modülleri varken Arduino'da bunlar kullanılmak istense harici olarak eklenmesi gerekmektedir. Bu hem çalışmanın karmaşıklaşmasına hem de fazladan iş yüküne neden olmaktadır. RPi'de desteklenen temel programlama dili Python'dur. Python programlama dili ile yapay zekâ uygulamaları geliştirmek Arduino'da kullanılan C tabanlı programlama diline göre daha kolaydır. Bunun yanı sıra RPi'de bazı sensör ve komponentlerin kullanımı Arduino'ya göre oldukça karmaşıktır. Temelde bu sorunları ortadan kaldırmak için iki mikrodenetleyiciye de çalışmada yer verilmiştir.

3.2.2.2. Sensör ve Elektronik Bileşenler

Çalışmada akıllı ev sistemi içerisinde LDR ışık sensörü, alev algılama sensörü, MQ5 yanıcı gaz algılama sensörü (LPG ve propan gazı), röle modülleri, yağmur algılama sensörü, ses sensörü, DHT11 sıcaklık ve nem sensörü, PIR sensörü, kamera modülü, GSM modülü, fan modülü, çeşitli kablolar, breadboard, direnç, güç kabloları, LM2596 voltaj regülatörü, MCP3008 entegresi ve 12V adaptör gibi sensör ve elektronik bileşenler kullanılmıştır.

LDR sensörü, ışığa duyarlı bir devre elemanıdır. Piyasada 5 mm ve 10 mm büyüklüğünde sensörler mevcuttur. Işık şiddetine bağlı olarak üzerindeki direncin değeri değişkenlik gösterir. Bu analog değişkenliğe göre ışık şiddeti ölçülmektedir. Işık şiddeti arttıkça direnç değeri azalır,

ışık şiddeti azaldıkça direnç değeri artar. LDR sensörünün maksimum çalışma sıcaklığı 60 °C'dir. Örnek bir LDR sensörü Şekil 3.7'de gösterilmiştir.



Şekil 3.7. LDR sensörü [73].

Alev algılama sensörü, belirli bir dalga boyundaki (760 nm – 1100 nm) ateşi tespit etmek için kullanılan bir sensördür. Ateşin şiddetine göre geriye dijital olarak 0 ya da 1 değeri gönderir. Üzerindeki trimpot ile hassasiyet ayarı yapılabilmektedir. Sensör kartının çalışma voltajı 5V'dur. Üzerinde bir IR alıcısı mevcuttur. Örnek bir alev algılama sensörü Şekil 3.8'de gösterilmiştir.



Şekil 3.8. Alev algılama sensörü [74].

MQ5 yanıcı gaz algılama sensörü 5V gerilim ile çalışan, dijital ve analog çıkış verebilen bir sensör kartıdır. MQ5 sensörü izobütan ve 300-10.000 ppm konsantrasyonlarında propan gazı algılayabilirler. Bu sensörün RPi ile kullanılabilmesi için MCP3008 analog-dijital çevirici kullanmak gerekmektedir. Örnek bir MQ5 yanıcı gaz algılama sensörü Şekil 3.9'da gösterilmiştir.




Şekil 3.9. MQ5 yanıcı gaz algılama sensörü [75].

Röle modülleri üzerindeki voltaj değerlerine göre uygun elektrikli aletlerin kontrol edilmesini sağlayan bir modüldür. İhtiyaca göre tek kanallı ve çok kanallı olarak satın alınabilirler. Röle modüllerini kullanırken en dikkat edilmesi gereken şey modülün üzerindeki giriş/çıkış voltaj ve amper değerleridir. Çalışmada şerit ledlerin kontrolü için kullanılan röle modülü Şekil 3.10'da gösterilmiştir.



Şekil 3.10. Çift kanallı röle modülü [76].

Yağmur algılama sensörü, birbirlerine paralel olarak yerleştirilmiş iletkenlerden oluşan bir devre kartıdır. Bu devre kartı üzerine su temas ettiği zaman sensör çıkış pinine analog ve dijital değer gönderir. Bu değerleri okuyarak yağmur yağıp yağmadığını algılayabiliriz. Örnek bir yağmur algılama sensörü Şekil 3.11'de gösterilmiştir.



Şekil 3.11. Yağmur algılama sensörü [77].


Ses sensörü, ortamdaki ses seviyesinin şiddetine göre dijital ve analog çıkış verebilen bir sensördür. Üzerindeki potansiyometre ile istenilen hassasiyet ayarı yapılabilir. Çalışma voltajı 4-6V'dur. Üzerinde LM393 çipi ve elektret kondansatör mikrofona mevcuttur. Örnek bir ses sensörü Şekil 3.12'de gösterilmiştir.



Şekil 3.12. Ses sensörü [78].

DHT11 sıcaklık ve nem sensörü, ortamdaki sıcaklık ve nem değerini ölçerek dijital sinyal çıkışı verebilen gelişmiş bir sensördür. Üzerinde 8 bitlik bir mikroişlemci vardır. 0-50 °C sıcaklığı 2 santigrat derece hata payı ile ölçmekte ve %20-90 RH arasındaki nem değerlerini de %5 RH

hata payı ile ölçmektedir. Normalde 4 pinli olarak kullanılan sensör, hazır devre kartıyla daha kolay bir kullanıma sahiptir. Çalışma gerilimi 5V'tur. Örnek bir DHT11 sıcaklık ve nem sensörü Şekil 3.13'te gösterilmiştir.



Şekil 3.13. DHT11 sıcaklık ve nem sensörü [79].


PIR hareket sensörü, ortamdaki canlı hareketleri algılamak için kullanılır. Dijital çıkışlı olan sensör, ortamda hareket olmadığı zaman lojik 0, hareket olduğu zaman ise lojik 1 çıkış değeri vermektedir. Sensör üzerinde 2 adet trimpot bulunmaktadır. Biri sensörün görme mesafesini, diğeri ise sensörün hareket algıladıktan sonra ne kadar süre daha lojik 1 çıkış değeri vereceğini ayarlamakta kullanılır. Çalışma voltajı 5-12V'tur. Genel hassasiyet algılama aralığı 3-5 m ve görüş açısı 140°'dir. Örnek bir PIR sensörü Şekil 3.14'te gösterilmiştir.



Şekil 3.14. PIR sensörü [80].

Kamera modülü olarak doğrudan RPi'ye bağlanan bir modül kullanılmıştır. 5 megapiksel çözünürlüğe sahip ve sabit odaklı bir lensi mevcuttur. Modülde kullanılan sensör tipi OmniVision

OV5647'dir. Görüş açısı 54 x 41 derece, görüş alanı 2m'de 2.0 x 1.33m'dir. Tam kare SLR lens eşdeğeri 35mm'dir. Kamera modülü ile fotoğraf çekebilmek ve video kaydı alabilmek mümkündür. Örnek bir kamera modülü Şekil 3.15'te gösterilmiştir.



Şekil 3.15. Kamera modülü [81].


Çalışmada kullanılan fan modülü, kendi üzerinde L9110 motor sürücü entegre bulundurmaktadır. Kart üzerinde 4 pin yer almaktadır ve besleme voltajı 5V'tur. Bu modül çalışmada klima yerine kullanılmaktadır. Örnek fan modülü Şekil 3.16'da gösterilmiştir.



Şekil 3.16. Fan modülü [82].


Servo motor, belirli açılarda dönebilen ve hatasız hız ve ivme kontrolü yapabilen motor türüdür. Bu motorlar robotik projelerde sıklıkla kullanılmaktadır. Genelde dönme açıları 180° ile

sınırlıdır ama 360° dönebilen servo motorlar da mevcuttur. Servo motorlar sinyal genişlik modülasyonu (PWM) ile çalışırlar. Örnek bir servo motor Şekil 3.17’de gösterilmektedir.



Şekil 3.17. Servo motor [83].

GSM modülü geliştirme projeleri için tasarlanan ve bir telefonun iletişimle ilgili yapabileceği neredeyse her şeyi yapabilen elektronik bir devredir. GSM modülü ile SMS gönderme, telefon görüşmeleri, internete bağlanma gibi birçok işlem yapılabilir. Çalışma kapsamında GSM modülünün SIM800L modeli kullanılmıştır. Modülün çalışma voltajı 3.4 - 4.4V arasındadır. Örnek GSM modülü Şekil 3.18’de gösterilmektedir.




Şekil 3.18. GSM modülü [84].

LM2596 voltaj regülatörü, sistemdeki şerit ledleri besleyen 12V adaptördeki voltaj değerini 5V'a düşürmek için kullanılmıştır. Böylece fazladan bir güç kaynağı kullanımına gerek kalmamıştır. Kartın giriş gerilimi 4-35V, çıkış gerilimi ise 1.25-30V'dur. Kart 3A'e kadar üzerinden akım geçirebilmektedir. LM2596 voltaj regülatörünün görseli Şekil 3.19'da verilmiştir.



Şekil 3.19. LM2596 voltaj regülatörü [85].

MCP3008 entegresi, 2.7-5.5V arası besleme gerilimi ile çalışan bir analog/dijital çeviricidir. Bu entegre 10 bitlik çözünürlük ve 200kSPS örnekleme hızına sahiptir. Çalışmada bu entegre MQ5 gaz sensörü ile analog değer okumak için kullanılmıştır. MCP3008 entegresinin görseli Şekil 3.20'de verilmiştir.




Şekil 3.20. MCP3008 entegresi [86].

Çalışmanın prototipleme aşamasını kolaylaştırması için GPIO çoklu kablo modülü ve breadboard kullanılmıştır. Malzemelerin görsellerine Şekil 3.21 ve 3.22’de yer verilmiştir.



Şekil 3.21. GPIO çoklu kablo modülü [87].



Şekil 3.22. Breadboard [88].

Bu tez kapsamında tasarlanan akıllı ev içerisindeki aydınlatma sistemi için farklı renklerde şerit ledler kullanılmıştır. Bu ledler genellikle 12V ile çalışmaktadır. Görsel Şekil 3.23'te verilmiştir.

Tüm sistemi beslemek için RPi güç adaptörü ve 12Vluk bir adaptör kullanılmıştır.




Şekil 3.23. Şerit led.

3.2.3. Geliştirme Ortamı

Temel geliştirme ortamı RPi üzerinde çalışan Raspbian işletim sistemidir (Raspbian OS). Projeyi geliştirmek için bu işletim sistemi üzerinde Python programlama dili ve Arduino (Tümleşik Geliştirme Platformu) IDE kullanılmıştır.


Raspbian, RPi için tasarlanmış Debian tabanlı bir işletim sistemidir. Mike Thompson ve Peter Green tarafından bağımsız bir proje olarak ortaya çıkmıştır. 2015 yılından bu yana Raspberry Pi Vakfı tarafından RPi'ler için resmi işletim sistemi olarak sunulmaktadır. Raspbian Stretch ve Raspbian Buster gibi birçok sürümü mevcuttur. Bu işletim sistemi RPi'lerde kullanılan düşük performanslı ARM işlemcileri için optimize edilmiştir. Örnek bir Raspbian Buster masaüstü Şekil 3.24'te gösterilmektedir.




Şekil 3.24. Raspbian OS.

Raspbian işletim sisteminin temelinde Python programlama dili yatmaktadır. Python, 1990'lı yılların başında Guido Van Rossum tarafından Amsterdam'da geliştirilmeye başlanmıştır. Python, nesne yönelimli, bilimsel ve etkileşimli yüksek seviyeli bir programlama dilidir. Linux, Unix, Windows, Mac gibi birçok platformda çalışabilir. Özellikle veri bilimi ve yapay zekâ uygulamalarında çok fazla kütüphane desteği olduğu için insanlar tarafından sıkça tercih edilmektedir. Python programlama dili ile sadece masaüstü ve terminal uygulamaları değil web siteleri ve Android tabanlı mobil uygulamalar yapmak da mümkündür. Şekil 3.25'te Raspbian işletim sistemi içinde bir Python terminal ara yüzü gösterilmiştir. Bu çalışmada Python 3.7.3 versiyonu kullanılmıştır. Yapay zekâ sınıflandırma yöntemleri için Scikit-Learn kütüphanesi kullanılmıştır. Scikit-Learn Python programlama dili için ücretsiz bir makine öğrenmesi kütüphanesidir. Scikit-Learn projesi 2007 yılında David Cournapeau tarafından bir Google yaz projesi olarak başlamıştır. Daha sonra proje Fransa'nın Rocquencourt kentindeki Fransız Bilgisayar Bilimi ve Otomasyon Araştırmaları Enstitüsü tarafından üstlenilmiştir. Bu kütüphane şu anda GitHub'daki en popüler makine öğrenme kütüphanelerinin başında gelmektedir. Spotify,

EverNote, Booking gibi büyük şirketler de bu kütüphaneden yararlanmaktadır [89]. Bu kütüphanenin algoritma şeması Şekil 3.26'da gösterilmiştir.




Şekil 3.25. Python terminal.



Şekil 3.26. Scikit-Learn algoritma şeması [90].

Kullanılan bir diğer geliştirme ortamı da Arduino IDE'dir. Arduino IDE, Arduino modelleri içine programın yazılmasına, derlenmesine ve derlenen kodun Arduino kartı içerisine yüklenmesine olanak sağlayan bir yazılım geliştirme platformudur. Windows, Linux ve MacOS işletim sistemleri için uyumlu sürümleri mevcuttur. Arduino IDE, özel kod yapılandırma kurallarını kullanarak C ve C++ programlama dillerini desteklemektedir. Temel olarak içerisinde 2 fonksiyon barındırmaktadır. Setup fonksiyonu Arduino kartının pinlerine bağlanan devre elemanlarını kod içerisinde tanımlamak, seri haberleşmeyi başlatmak ve program çalıştığında ilk olarak yürütülen kodları barındırmak için kullanılır. Loop fonksiyonu ise bir döngü fonksiyonudur. İçerisine yazılan kodlar sonsuz bir döngüye girmekte ve kendilerini sürekli tekrarlamaktadır. Bir Arduino IDE arayüzü Şekil 3.27'de gösterilmiştir.



Şekil 3.27. Arduino IDE arayüzü.

3.3. Akıllı Ev Yönetim Sistemi

Akıllı ev sistemi geliştirilmesi için öncelikle sistemin nasıl bir algoritma ile çalışacağı tasarlanmıştır. Bunun için daha önce yapılan akıllı ev sistemleri detaylı olarak incelenmiştir. İncelenen sistemlerde hangi teknolojilerin kullanıldığı, donanım altyapıları, haberleşme

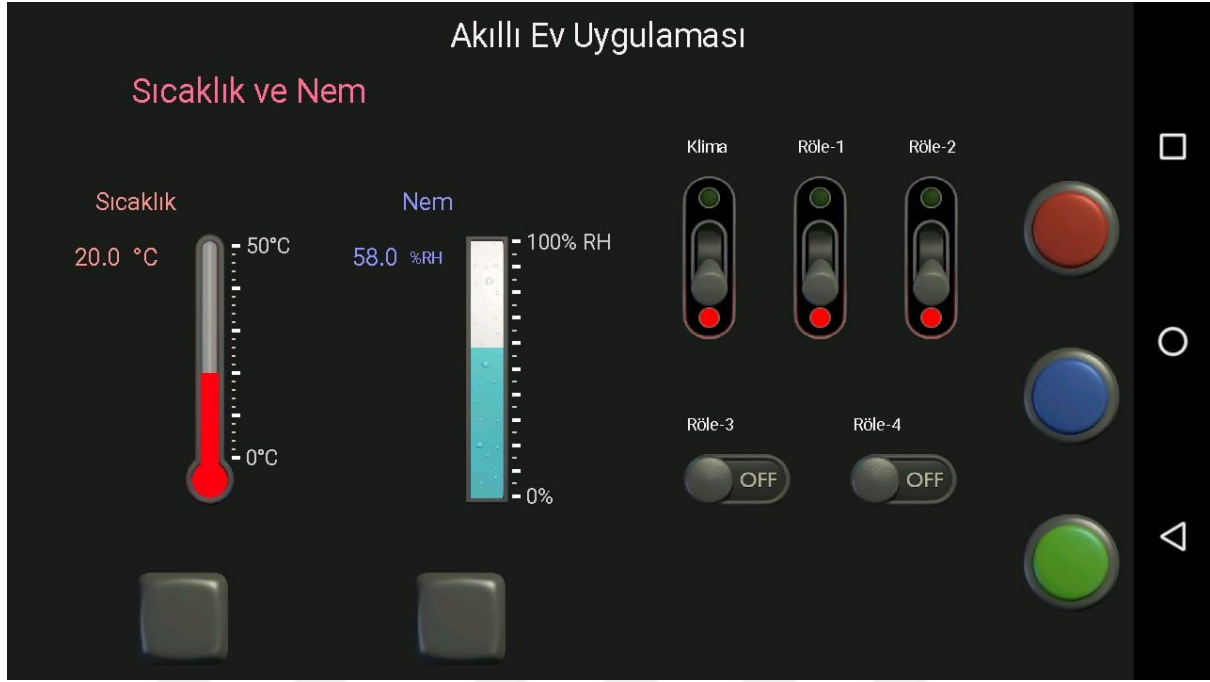
protokolleri, eksikleri ve çalışma kapsamında geliştirilecek sistemde ne gibi yenilikler yapılacağı araştırılmıştır.

Geliştirilen sistemin nasıl bir algoritma ile çalışacağı tasarlandıktan sonra uzaktan yönetim için kullanılacak haberleşme protokolleri belirlenmiştir. Sistemin genel algoritması ve haberleşme türlerinin de belirlenmesinin ardında sistemde kullanılacak donanım altyapısı belirlenmiştir. Donanımlar belirlenirken uygun maliyet, sürdürülebilirlik ve maksimum performans kriterleri göz önüne alınmıştır. Son olarak kullanılan donanımlara uygun şekilde yazılım hazırlanmış ve sistem hazır hâle getirilmiştir. Çalışmada tasarlanan akıllı ev yönetim sistemi Bluetooth kontrol modu, otonom kontrol ve güvenlik modu ve web kontrol modu ve yapay zekâ algoritması olmak üzere 4 kısımdan oluşmaktadır.

Bluetooth kontrol modunda, ev sakinleri evdeyken akıllı ev sistemini rahatça kullanabilecekleri mobil tabanlı bir sistem geliştirilmiştir. Android tabanlı telefonlarda çalışan uygulama sayesinde kullanıcılar cep telefonları üzerinden akıllı ev sistemindeki olası durumları izleyebilmekte ve belirli aktiviteleri rahatlıkla gerçekleştirebilmektedir. Kullanıcılar Android uygulamasıyla ev içerisindeki sıcaklık ve nem durumunu anlık olarak takip edebilmektedir. Aynı zamanda ev sakinleri ev içerisindeki aydınlatma sistemini, elektrikli ev aletlerini ve klimayı istedikleri zaman kontrol edebilmektedirler. Sistemin kontrolünü sağlayan Android uygulamasının arayüzleri Şekil 3.28 ve Şekil 3.29’da gösterilmiştir.



Şekil 3.28. Akıllı ev sistemi.



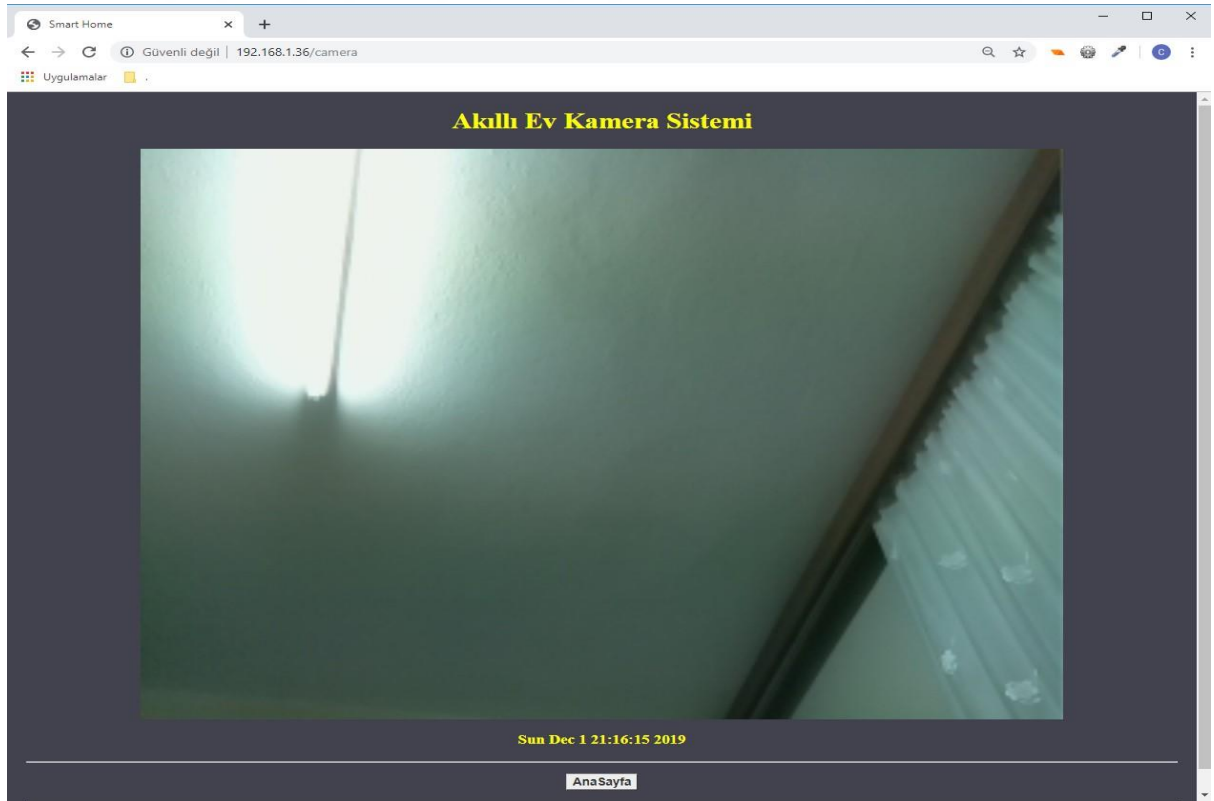
Şekil 3.29. Akıllı ev sistemi Android kontrol ara yüzü.

Otonom kontrol ve güvenlik modu ev sakinlerinin evde olmadığı durumlarda güvenlik amaçlı devreye giren sistemdir. Bu sistem, tamamen kullanıcı bağımsız bir sistemdir. Sistem, ev içinde herhangi bir nedenden dolayı çıkabilecek felaketleri algılayarak SMS yoluyla ev sakinlerini bilgilendirmektedir. Bu modda kapı, yangın gaz, ses, yangın, hareket ve yağmur alarmları bulunmaktadır. Kapı, hareket ve ses alarmları daha çok hırsızlara yönelik korunma sistemleridir.


Web kontrol modu ev sakinlerinin evden uzakta olduğu durumlarda internet bulunan her yerden akıllı ev sistemini yönetip izlemesini sağlayabilmektedir. Ev sakinleri web üzerinden aydınlatmaların ve elektrikli ev aletlerinin kontrolünü yapabilmekte iken aynı zamanda ev içindeki sıcaklık ve nem değerlerini görebilmektedirler. Bunun yanında akıllı evde bulunan kamera ile ev içerisindeki durum anlık olarak izlenebilmektedir. Web kontrol ara yüzü Şekil 3.30 ve Şekil 3.31’de gösterilmiştir. Çalışma kapsamında gerçekleştirilen akıllı ev sisteminin tüm elemanlarını barındıran Fritzing devre şeması Şekil 3.32’de gösterilmiştir.



Şekil 3.30. Akıllı ev sistemi web kontrol ara yüzü.



Şekil 3.31. Akıllı ev sistemi kamera izleme ara yüzü.



Şekil 3.32. Akıllı ev sistemi devre şeması.

Akıllı ev sisteminin yapay zekâ algoritması, Tablo 3.1'deki veri kümesine çeşitli sınıflandırma algoritmaları uygulanarak test edilmiştir. Sınıflandırma algoritmalarının amacı, evdeki kontrol edilecek elektronik eşyaların (röleler, perde vs.) durumunu geçmiş verilere dayanarak ev sakinlerinden önce kontrol etmektir. Böylece ev sakinlerinin yerine elektronik eşyaları otomatik olarak kontrol edebilen bir sistem geliştirilmiştir. Sınıflandırma yöntemleri veri kümesindeki J-R arasındaki nitelikler (akıllı ev sisteminin yapay zekâ algoritması tarafından otomatik olarak değiştirilmesi istenen nitelikler - J ve R nitelikleri dâhil) hedef alınarak uygulanmaktadır. Belirlenen tüm nitelikler için teker teker sınıflandırma işlemleri uygulanmıştır. Sınıflandırma işlemleri tamamlandıktan sonra elde edilen değerler tek bir satır olarak birleştirilerek o anki tarih ve sensör değerleriyle birlikte veri kümesine eklenmektedir. Değerler veri kümesine eklendikten sonra elde edilen sonuçlara göre evdeki elektronik eşyaların durumları sistem tarafından değiştirilmekte ve ev sakinlerine değişikliklerle ilgili bilgi mesajı gönderilmektedir.

3.4. Yöntemler

Çalışmada kullanılan tüm yöntemler Python ortamında eğitilip test edilmiştir. Tüm yöntemler için veri kümesi %80 eğitim ve %20 test verisi olarak iki gruba ayrılmış olup 10 katlı çapraz doğrulama yapılmıştır.

3.4.1. Lojistik Regresyon Algoritması

Lojistik regresyon (LR) alanındaki ilk çalışmalar 1944, 1953 ve 1955 yıllarında Berkson tarafından yapılmıştır [91]. LR algoritması, isminin aksine genelde sınıflandırma problemlerine daha uygun bir algoritmadır. LR yöntemi, sonuç değişkeninin iki veya çok düzeyli kategorik değişken olması, 0-1 gibi kesikli değerler alması durumunda kullanılmakta ve bağımlı değişken olumlu-olumsuz, az-orta-çok, başarılı-başarısız gibi kategorik değerlerden oluştuğunda tercih edilmektedir [92]. Çalışma kapsamında örnek verecek olursak, bir röle ya açıktır ya da kapalıdır. LR, bu örneğe benzer şekilde diğer durumları da sınıflandırmakta kullanılmaktadır [93]. Klasik lojistik model formülü (1)'de verilmiştir.

$$f(x) = \frac{1}{1+e^{-z}} \quad (1)$$

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan LR algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan LR algoritmasının özellikleri:

- Ceza kriteri (penalty): l2

- Durdurma kriteri (tol): $1e - 4$
- Sınıf ağırlıkları (class_weight): None
- Problemin çözümü için kullanılan algoritma (solver): lbfgs
- İterasyon sayısı (max_iter): 100

3.4.2. Naive Bayes Algoritması

Naive Bayes modeli oldukça basitleştirilmiş bir Bayesian olasılık modelidir. Naive Bayes sınıflandırıcısı, güçlü bir bağımsızlık varsayımına dayanmaktadır. Bu bir özniteliğin olasılığının diğerinin olasılığını etkilemediği anlamına gelir [94]. Örneğin bir meyve turuncu, yuvarlak ve çapı yaklaşık 15 cm ise portakal olarak kabul edilebilir. Saf bir Bayes sınıflandırıcısı, bu özelliklerin her birinin renk, yuvarlaklık ve çap özellikleri arasındaki muhtemel korelasyonlardan bağımsız olarak bu meyvenin bir portakal olma ihtimaline bağımsız olarak katkı sağladığını düşünmektedir. Naive Bayes algoritması birçok karmaşık gerçek dünya problemlerinde oldukça başarılı sonuçlar elde etmiştir. Bayes teoremi x_1 ve x_n sınıf değişkenine ve bağımlı özellik vektörüne göre (2)'deki ilişkiyi belirtir.

$$P(y | x_1, \dots, x_n) = \frac{P(y)P(x_1, \dots, x_n|y)}{P(x_1, \dots, x_n)} \quad (2)$$

Saf koşullu bağımsızlığın kullanılması (3)'te gösterilmiştir.

$$P(x_i|y, x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n) = P(x_i|y), \quad (3)$$

Tüm i 'ler için bu ilişkinin basitleştirilmiş hâli (4)'te gösterilmiştir.

$$P(y | x_1, \dots, x_n) = \frac{P(y) \prod_{i=1}^n P(x_i|y)}{P(x_1, \dots, x_n)} \quad (4)$$

$P(x_1, \dots, x_n)$ giriş verilen sabit olduğundan (5)'teki sınıflandırma kuralı kullanılmaktadır.

$$\begin{aligned} P(y | x_1, \dots, x_n) &\propto P(y) \prod_{i=1}^n P(x_i | y) \\ &\Downarrow \\ \hat{y} &= \arg \max_y P(y) \prod_{i=1}^n P(x_i | y), \end{aligned} \quad (5)$$

$P(y)$ ve $P(x_i | y)$ değerlerini tahmin etmek için Maksimum A Posteriori (MAP) tahmini kullanılabilir. $P(y)$ eğitim setinde y sınıfının göreceli frekansıdır. Farklı Naive Bayes

sınıflandırıcıları temel olarak $P(x_i | y)$ 'nin dağıtımıyla ilgili yaptıkları varsayımlara göre farklılık gösterirler. Basitleştirilmiş Naive Bayes sınıflandırıcıları gerçek dünyadaki belge sınıflandırma, mail spam filtreleme gibi durumlarda çok başarılı sonuçlar almışlardır. Gerekli parametreleri tahmin etmek için az miktarda eğitim verisi yeterlidir [95-96]. Naive Bayes algoritmasının 4 alt türü vardır. Bunlar Gaussian, Bernoulli, Multinomial ve Complement Naive Bayes algoritmalarıdır.

3.4.2.1. Gaussian Naive Bayes Algoritması

Naive Bayes sınıflandırmalarında sürekli özellikleri kullanmanın yolu Gauss dağılımlarıdır. Gaussian Naive Bayes sınıflarda şart koşulan özelliklerin gerçekleşme ihtimalini temsil etmek için kullanılmaktadır. Böylece her özellik Gauss olasılık fonksiyonu (PDF) ile tanımlanır ((6)) [97].

$$X_i \sim N(\mu, \sigma^2) \quad (6)$$

Gaussian PDF bir çan şeklindedir ve (7)'deki gibi tanımlanır.

$$P(x_i | y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \quad (7)$$

σ_y ve μ_y parametreleri maksimum olasılık kullanılarak tahmin edilir.

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan Gaussian Naive Bayes algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan Gaussian Naive Bayes algoritmasının özellikleri:

- Sınıfların öncelik olasılıkları (priors): None
- Hesaplama için kullanılan varyans (var_smoothing): $1e - 9$

3.4.2.2. Bernoulli Naive Bayes Algoritması

Bernoulli Naive Bayes, çok değişkenli Bernoulli dağılımlarına göre dağıtılan veriler için saf Bayes eğitim ve sınıflandırma algoritmalarını uygular; yani, birden fazla özellik olabilir ancak her birinin bir ikili değer değişkeni olduğu varsayılır. Bu nedenle, bu sınıf, örneklerin ikili değerli

özellik vektörleri olarak temsil edilmesini gerektirir [98]. Bernoulli Naive Bayes, örnekleri ikili hâle getirebilir. Bernoulli Naive Bayes karar kuralı (8)'de gösterilmiştir.

$$P(x_i | y) = P(i | y)x_i + (1 - P(i | y))(1 - x_i) \quad (8)$$

Bu model ikili terimlerden oluşan belgelerin kullanıldığı belge sınıflandırma görevleri için idealdir.

$$P(x | C_k) = \prod_{i=1}^n P_{ki}^{x_i} (1 - P_{ki})^{(1-x_i)} \quad (9)$$

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan Bernoulli Naive Bayes algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan Bernoulli Naive Bayes algoritmasının özellikleri:

- Yumuşatma parametresi (alpha): 1.0
- İkililik eşiği (binarize): 0.0
- Sınıf öncesi olasılıkların öğrenilip öğrenilmeyeceği (fit_prior): True
- Sınıfların önceki olasılıkları (class_prior): None

3.4.2.3. Multinomial Naive Bayes Algoritması

Multinomial Naive Bayes, genellikle metin kaynaklı işlemler ve metin sınıflandırma problemleri için kullanılmaktadır. Sınıfların C ile sözlük boyutunun N ile gösterildiğini varsayalım. Multinomial Naive Bayes, Bayes kuralını kullanarak en yüksek olasılıkla $Pr(c | t_i)$ olan sınıfa bir test belgesi atar [99]. Örnek (10)'da gösterilmiştir.

$$Pr(c | t_i) = \frac{Pr(c) Pr(c | t_i)}{Pr(t_i)}, \quad c \in C \quad (10)$$

$Pr(c)$ 'den önceki sınıf, c sınıfına ait belge sayısını toplam belge sayısına bölerek tahmin edebilir. $Pr(t_i | c)$, c sınıfında t_i gibi bir belge edinme olasılığıdır ve (11)'de gösterilmiştir.

$$Pr(t_i | c) = (\sum_n f_{ni})! \prod_n \frac{Pr(w_n|c)^{f_{ni}}}{f_{ni}!}, \quad (11)$$

Denklem (11)'deki f_{ni} , test belgesindeki n kelime sayısıdır. Ve $Pr(w_n|c)$ c sınıfı verilen n kelimesinin olasılığıdır. İkinci olasılık formülü (12)'de verilmiştir.

$$\widehat{Pr}(w_n | c) = \frac{1 + F_{nc}}{N + \sum_{x=1}^N F_{xc}}, \quad (12)$$

F_{xc} , c sınıfına ait tüm eğitim belgelerinde x kelimesinin sayımıdır ve Laplace tahmincisi, sıfır frekans probleminden kaçınmak için her kelimenin sayımını birer birer doldurmak için kullanılır [98-99]. Denklem (10)'daki normalizasyon faktörü $Pr(t_i)$ kullanılarak hesaplanabilir ve (13)'te gösterilmiştir.

$$Pr(t_i) = \sum_{k=1}^{|C|} Pr(k) Pr(t_i|k) \quad (13)$$

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan Multinomial Naive Bayes algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan Multinomial Naive Bayes algoritmasının özellikleri:

- Yumuşatma parametresi (alpha): 1.0
- Sınıf öncesi olasılıkların öğrenilip öğrenilmeyeceği (fit_prior): True
- Sınıfların önceki olasılıkları (class_prior): None

3.4.2.4. Complement Naive Bayes Algoritması

Complement Naive Bayes, Multiominal Naive Bayes algoritmasının özellikle dengesiz veri kümeleri için uygun olan bir uyarlamasıdır. Spesifik olarak Complement Naive Bayes, modelin ağırlıklarını hesaplamak için her bir sınıfın tamamlayıcısının istatistiklerini kullanır. Bu algoritmanın mucitleri, ampirik olarak yöntemin parametre tahminlerinin Multinomial Naive Bayes'e göre daha istikrarlı olduğunu göstermişlerdir. Modelin ağırlık hesaplama prosedürü (14)'te gösterilmiştir [100-101].

$$\begin{aligned} \hat{\theta}_{ci} &= \frac{\alpha_i + \sum_{j:y_j \neq c} d_{ij}}{\alpha + \sum_{j:y_j \neq c} \sum_k d_{kj}} \\ w_{ci} &= \log \hat{\theta}_{ci} \\ w_{ci} &= \frac{w_{ci}}{\sum_j |w_{cj}|} \end{aligned} \quad (14)$$

Toplamlar c sınıfında olmayan tüm j belgelerinin üzerindeyse, d_{ij} j belgesindeki i teriminin ya sayım ya da tf-idf değeridir. α_i , Multinomial Naive Bayes ve $\alpha = \sum_i \alpha_i$ 'de bulunan gibi bir yumuşatıcı parametredir.

Bu çalışmada Tablo 3.1’de belirtilen veri kümesi kullanılan Complement Naive Bayes algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan Complement Naive Bayes algoritmasının özellikleri:

- Yumuşatma parametresi (alpha): 1.0
- Sınıf öncesi olasılıkların öğrenilip öğrenilmeyeceği (fit_prior): True
- Sınıfların önceki olasılıkları (class_prior): None

3.4.3. K-En Yakın Komşu Algoritması

K-En Yakın Komşu (KNN) algoritması, sınıflandırma problemlerini ve yerel özellikler tarafından açıklanan görüntüleri çözen denetimli öğrenme yöntemleri arasında yer alır. Yerel bir sorgu vektörü ve bir dizi özellik göz önüne alındığında, KNN algoritması, sorgu vektörünün en yakın özellik vektörlerini arar. Yani sorgu vektörü ile diğer tüm vektörlerin arasındaki mesafeyi hesaplar ve hesaplanan mesafeleri sıralar. Daha sonra en küçük mesafelere karşılık gelen k referans vektörlerini seçer [102-103]. $W = \{x_1, x_2, \dots, x_n\}$ değerini n etiketli bir örnek sayarsak pseudo kodu aşağıdaki gibidir [104]:

BEGIN

Sınıflandırılmayan y girişi.

K’yi, $1 \leq K \leq n$ değerleri arasında ayarla.

i = 1 olarak başlat.

DO UNTIL (En yakın K komşuları bulundu)

y ve x_i arasındaki mesafeyi hesapla.

IF ($i \leq K$) **THEN**

x_i ’yi en yakın K komşu kümesine dâhil et.

ELSE IF (x_i y’ye önceki en yakın komşulardan daha yakındır) **THEN**

En yakın K komşuları kümesindeki en uzak mesafeyi silin.

x_i ’yi en yakın K komşu kümesine ekleyin.

END IF

i’yi arttır.

END DO UNTIL

K-en yakın komşu kümesinde temsil edilen çoğunluk sınıfını belirleyin.

IF (i bağı var) **THEN**

Bağlanan her sınıftaki komşu mesafelerinin toplamını hesaplayın.

IF (bağlantı yoksa) **THEN**

y’yi minimum toplam sınıfında sınıflandırın.

ELSE

y’yi bulunan son minimum sınıfında sınıflandırın.

END IF


ELSE

y’yi çoğunluk sınıfında sınıflandırın.

END IF

END

KNN algoritmasında uzaklıkları tespit etmek için farklı yöntemler kullanılmaktadır. Problemlere göre bu yöntemler değişebilir. En sık kullanılan yöntemler; Euvclidean, Minkowski, Manhattan yöntemleridir. Örnek bir KNN yapısı Şekil 3.33'de gösterilmiştir.



Şekil 3.33. KNN yapısı [105].

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan KNN algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan KNN algoritmasının özellikleri:

- Komşu sayısı (n_neighbors): 5
- Ağırlıklar (weights): uniform
- Komşuları hesaplamak için kullanılan algoritma (algorithm): auto
- Yaprak boyutu (leaf_size): 30
- Minkowski metriği için güç parametresi: 2
- Mesafeleri hesaplamak için kullanılan metrik (metric): minkowski


3.4.4. Karar Ağaçları Algoritması

Karar ağaçları, gözetimli öğrenmede en çok kullanılan algoritmalarından biridir. Daha önceden belirlenmiş bir hedef değişkenine sahiptir. Tasarımı itibariyle en tepeden en aşağı kadar inen bir strateji sunmaktadır. Bir veri kümesini bazı kurallara göre daha küçük parçalar haline getirir. Karar ağaçları, hem kategorik hem de sayısal verileri işleyebilir. Karar ağacı algoritması, hedef değişken tipine göre farklılık gösterebilir. En sık kullanılan algoritmalar entropi ve gini algoritmalarıdır. Entropi, verilerle ilgili bir belirsizlik ölçüsüdür. Entropi ilk defa 1948 yılında

Claude E. Shannon tarafından tanımlanmıştır. Karar ağacı algoritmalarında entropi en aza indirecek şekilde kullanılmalıdır. Entropi, formülü (15)'te gösterilmiştir [106].

$$H(X) = - \sum_i p(x_i) \log p(x_i) \quad (15)$$

En sık kullanılan karar ağacı algoritmaları; C4.5, CART, ID3, CHAID. Örnek bir karar ağacı yapısı Şekil 3.34'da gösterilmiştir.



Şekil 3.34. Karar ağacı yapısı [107].

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan karar ağacı algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan karar ağacı algoritmasının özellikleri:


- Bölmenin kalitesini ölçme işlevi (criterion): gini
- Her düğümdeki bölünmeyi seçmek için kullanılan yöntem (splitter): best
- Minimum örnek sayısı (min_samples_split): 2
- Yaprak düğümündeki minimum örnek sayısı (min_samples_leaf): 1
- Tüm girdi örneklerinin minimum ağırlıklı fraksiyonu (min_weight_fraction_leaf): 0.0

3.4.5. Destek Vektör Makineleri Algoritması

Destek vektör makineleri (SVM), yapısal risk minimizasyon prensibine göre çalışan dış bükey optimizasyon tabanlı bir makine öğrenme algoritmasıdır. SVM, sınıflandırma ve örüntü


tanıma problemleri için 1963 yılında Vapnik tarafından geliştirilmiştir [108]. SVM, temel olarak iki sınıfa ait verileri birbirinden ayırmak için kullanılır. Bu ayırma işlemi için karar sınırları ya da hiper düzlemler belirlenir. SVM algoritmaları temel olarak 2'ye ayrılır; Doğrusal SVM ve doğrusal olmayan SVM.

Doğrusal SVM sınıflandırmasında, iki sınıfa ait örneklerin doğrusal olduğunu varsayarsak, bu iki sınıfın bir karar fonksiyonu ile birbirinden ayrılması gerekir. Veri kümesini ikiye ayıran doğruya karar doğrusu denmektedir. Amaç en uygun karar doğrusunu bulmaktır. Karar doğrusunun veriye karşı dayanıklı olabilmesi için, sınır çizgisinin her iki sınıfın sınır çizgisine en yakın uzaklıkta olması gerekir. Karar çizgisine en yakın noktalar destek noktası denilmektedir. Doğrusal SVM örneği Şekil 3.35'de gösterilmektedir.



Şekil 3.35. Doğrusal SVM [109].

Doğrusal olmayan SVM'de ise, SVM'ler sınıfların dağılımından dolayı doğrusal bir hiper düzlem çizemezler. Bunun için çekirdek numaraları (kernel trick) kullanılır. Bu yöntem, doğrusal olmayan verilerde makine öğrenimini yüksek derecede arttırmaktadır. En sık kullanılan çekirdek yöntemleri; Gaussian RBF (Radyal Tabanlı Fonksiyon) Çekirdeği ve polinomal çekirdek yöntemleridir. Doğrusal olmayan SVM örneği Şekil 3.36'de gösterilmektedir.



Şekil 3.36. Doğrusal olmayan SVM [109].

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan SVM algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan SVM algoritmasının özellikleri:

- Düzenleme parametresi (C): 1.0
- Algoritmada kullanılan çekirdek türü (kernel): rbf
- Polinom çekirdek fonksiyonunun derecesi (degree): 3
- Rbf için çekirdek katsayısı (gamma): scale
- Durdurma kriteri toleransı (tol): $1e - 3$

3.4.6. XGBoost Algoritması

XGBoost algoritması, bir gradient boosting çerçevesi kullanan karar ağacı temelli bir topluluk makine öğrenme algoritmasıdır. Yapılandırılmamış veri içeren tahmin problemlerinde YSA ve diğer tüm algoritmalarından daha iyi performans gösterme eğilimindedir. XGBoost algoritması, Washington Üniversitesi'nde bir araştırma projesi olarak geliştirilmiştir. Tianqi Chen ve Carlos Guestrin, 2016 yılında SIGKDD Konferansı'nda XGBoost hakkında ilk makalesini sunmuştur [110-111]. XGBoost algoritmasının özü, objektif fonksiyonun değerini optimize etmektir. XGBoost algoritması tahmin ve tarih günleri arasındaki benzerliği hesaplamak ve özellik puanlarını elde etmek için özellik vektörlerinin kullanılmasından farklı olarak, gradyan artırma, güçlendirilmiş ağaç algoritmalarını kullanır. Böylece her özelliğin eğitim modeline etkisini göstermektedir. Algoritma kazanç, sıklık ve örtme ile önem kazanmaktadır. Ağaç dallarında her bir özelliğin öneminin ana referans faktörü kazançtır [112]. XGBoost algoritmasının pseudo kodu aşağıdaki gibidir [113]:

Data: Veri kümesi ve hiperparametreler

$f_0(x)$ fonksiyonunu başlat.

For $k = 1, 2, \dots, M$ **do**

$g_k = \frac{aL(y,f)}{a_f}$; değerini hesapla.

$h_k = \frac{a^2 L(y,f)}{a_f^2}$; değerini hesapla.

Maksimize kazanç ile bölünmeleri seçerek yapıyı belirle.

$A = \frac{1}{2} \left[\frac{G_L^2}{H_L} + \frac{G_R^2}{H_R} - \frac{G^2}{H} \right]$;

$w^* = -\frac{G}{H}$; yaprak ağırlıklarını belirle.

$\hat{b}(x) = \sum_{j=1}^T w_j$; temel öğreniciyi belirle.


$f_k(x) = f_{k-1}(x) + \hat{b}(x)$; ağaç ekle.

End

Result: $f(x) = \sum_{k=0}^M f_k(x)$

3.4.7. Çok Katmanlı Perceptron Algoritması

Çok katmanlı Perceptron algoritması (MLP), bir veri kümesi üzerinde eğitim alarak bir işlevi öğrenebilen denetimli bir öğrenme algoritmasıdır. Şekil 3.37’de tek katmanlı bir MLP ağı gösterilmiştir.



Şekil 3.37. Tek katmanlı MLP ağı [114].

MLP aslında bir YSA'dır. Birden fazla algılayıcıdan oluşur. Veri girişini almak için bir giriş katmanından, giriş hakkında karar veya tahmin yapan bir çıkış katmanından ve bu iki katman arasında MLP'nin gerçek hesaplamalı motoru olan rastgele sayıda gizli katmandan oluşur. Bir gizli katmanı olan MLP'ler herhangi bir sürekli fonksiyona yaklaşabilir. MLP algoritmaları genellikle derin öğrenme problemlerinde kullanılır. Girdiler ve çıktılar üzerinde eğitim kümesini alırlar, bu girdiler ve çıktılar arasındaki kolerasyonu modellemeyi öğrenirler. Eğitim, hatayı en aza indirmek için parametrelerin veya modelin ağırlıklarını ayarlamasıdır. Geriye doğru yayılma, bu hataya göre ağırlık ayarlamalarını yapmak için kullanılır ve ortalama kare hatası (RMSE) dâhil olmak üzere çeşitli şekillerde ölçülebilir. MLP'nin avantajları; doğrusal olmayan modelleri öğrenebilme, partial-fit kullanarak gerçek zamanlı modelleri öğrenebilme yeteneği.

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan MLP algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan MLP algoritmasının özellikleri:

- Gizli katmanda bulunan nöron sayısı (hidden_layer_sizes): 100
- Aktivasyon fonksiyonu (activation): relu
- Ağırlık optimizasyonu algoritması (solver): lbfgs
- Öğrenme oranı (learning_rate): constant
- Durdurma kriteri toleransı (tol): $1e - 4$
- İterasyon sayısı (max_iter): 200


3.4.8. Rassal Orman Algoritması

Rassal orman algoritması (RF), her sınıflandırıcının giriş vektöründen bağımsız olarak örneklenmiş bir rastgele vektör kullanılarak üretildiği ve her ağacın, bir giriş vektörünü sınıflandırmak için kullanılan bir ağaç sınıflandırıcı algoritmasıdır [115]. Örnek bir RF yapısı Şekil 3.38'de gösterilmiştir. RF algoritması, birkaç karar ağacının kombinasyonuna dayanan bir sınıflandırma yöntemler grubu oluşturur. Bu grupların ağaç esaslı bileşenleri belirli bir miktarda rastgelelik ile oluşmaktadır. Bu düşünceye dayanarak, RF karar ağaçlarının randomize topluluklarının genel bir prensibi olarak tanımlanır. Yani RF algoritması, birden fazla karar ağacını oluşturur ve daha kararlı bir tahmin elde etmek için onları birleştirir. RF algoritmasının en büyük avantajı, hem sınıflandırma hem de regresyon problemlerinde rahatlıkla kullanılabilmesidir. RF algoritması, en büyük boyutta ağaç geliştirmek için CART (Sınıflandırma ve Regresyon Ağaçları) metodolojisini kullanır. CART yönteminde, bir düğümde belirli bir ölçüt kullanılarak bölme işlemi gerçekleştirilir. Bölme işlemlerinde homojen sınıf dağılımına sahip düğümler tercih edilir. Düğümün homojenliğinin ölçülmesinde; Gini İndeksi, Entropi gibi farklı

ölçütler kullanılmaktadır. RF algoritması genelde Gini indeksini kullanmaktadır. Gini indeks formülü (16)'da gösterilmiştir.

$$Gini(T) = 1 - \sum_{j=1}^n (P_j)^2 \quad (16)$$

Gini indeks ölçümleriyle, en küçük Gini indeksine sahip olan bölünme pozisyonu belirlenir. Gini indeksi küçüldükçe sınıf homojenliği artar, büyüldükçe sınıf heterojenliği artar. Gini indeksi sıfır olduğunda ağaç dallanma işlemi sona erer. Son aşama girdi verisinin sınıflandırma işlemidir. RF algoritması, girdi verisini ormandaki her bir ağaçta yerleştirir. Daha sonra ağaçlar arasında bir oylama yapılır ve en çok oyu alan ağaç bir sınıfa atanır [116].



Şekil 3.38. Rassal orman ağaç yapısı [117].


Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan RF algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan RF algoritmasının özellikleri:

- Ağaç sayısı (n_estimators): 100
- Bölmenin kalitesini ölçme işlemi (criterion): gini
- Bir iç düğümü ayırmak için gereken minimum örnek sayısı (min_samples_split): 2
- Yaprak düğümündeki minimum örnek sayısı (min_samples_leaf): 1
- Tüm girdi örneklerinin minimum ağırlıklı fraksiyonu (min_weight_fraction_leaf): 0.0


3.4.9. Stochastic Gradient Descent Algoritması

Gradient descent (GD), makine öğrenmesi ve derin öğrenmede çok popüler bir optimizasyon tekniğidir ve öğrenme algoritmalarının hepsinde olmasa da çoğunda kullanılır. Gradyan, temel olarak bir fonksiyonun eğimidir. Matematiksel olarak, girdilerine göre bir dizi parametrenin kısmi türevleri olarak tanımlanabilir. Eğim ne kadar fazlaysa, o kadar dik olur. GD, maliyet fonksiyonunu mümkün olan en aza indiren bir fonksiyonun parametrelerinin değerini bulmak için kullanılan yinelemeli bir yöntemdir. Parametreler başlangıçta belirli bir değer olarak tanımlanır.

Stochastic kelimesi, rastgele bir olasılık ile bağlantılı bir sistem anlamına gelmektedir. Stochastic gradient descent (SGD) algoritmasında, her bir yineleme için ayarlanan verilerin tamamı yerine rastgele birkaç örnek seçilir. Örnek olarak veri kümesinde bir milyon örnek olduğunu varsayalım. Klasik GD algoritması kullanıldığında bir yinelemeyi gerçekleştirmek için bir milyon örneğin tamamının kullanılması gerekir. Dolayısıyla işlem çok maliyetli bir duruma dönüşmektedir. Bu veri kümesi SGD algoritması ile çözüldüğünde, her bir yinelemeyi gerçekleştirmek için sadece bir numune veri (bir parça) alır. Ve bu veri rastgele karıştırılır. Böylece SGD'de tüm örneklerde maliyet fonksiyonunun gradyanının toplamı yerine her bir yinelemede tek bir örneğin maliyet fonksiyonunun gradyanını buluyoruz. SGD algoritmasında, veri kümesinden yalnızca bir örnek her yineleme için rastgele seçildiğinden, algoritmanın minimuma ulaşmak için kullandığı yok GD yöntemine göre daha gürültülüdür. GD ve SGD yöntemleri için örnek bir görsel Şekil 3.39 ve Şekil 3.40'te verilmiştir.



Şekil 3.39. GD algoritması tarafından alınan yol [118].



Şekil 3.40. SGD algoritması tarafından alınan yol [118].

Bu çalışmada Tablo 3.1’de belirtilen veri kümesi kullanılan SGD algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan SGD algoritmasının özellikleri:

- Ceza kriteri (penalty): l2
- Kayıp fonksiyonu (loss): hinge
- İterasyon sayısı (max_iter): 1000
- Durdurma kriteri toleransı (tol): $1e - 3$
- Öğrenme oranı (learning_rate): optimal
- Sınıf ağırlıkları (class_weight): balanced

3.4.10. Gaussian Süreç Algoritması

Gaussian süreç sınıflandırma algoritması (GPC), test tahminlerinin sınıf olasılıkları biçimini aldığı, daha özel olasılıklı sınıflandırma için Gauss işlemlerini (GP) uygular. GPC, parametrik olmayan bir sınıflandırma yöntemidir. Bir Bayesian metodolojisine dayanır. Çok etkili bir sınıflandırma yöntemidir. 1970’lerde O’Hagan ve arkadaşları tarafından istatistik alanında kullanılmak üzere geliştirilmiştir. Daha sonra makine öğrenmesi topluluğunda MacKay, Williams ve Rasmussen tarafından popülerleşmiştir.

GPC, rastgele değişken çiftleri arasındaki doğrusal olmayan ilişkileri modellemek için güçlü bir algoritmadır. Gerçek işlevsel ilişki konusundaki belirsizliği göstermek için uygulanabilecek fonksiyonlar üzerinde bir dağılım tanımlar [119].

Bu çalışmada Tablo 3.1’de belirtilen veri kümesi kullanılan GPC algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan GPC algoritmasının özellikleri:


- Optimizasyon yöntemi (optimizer): fmin_l_bfgs_b
- İterasyon sayısı (max_iter): 100

3.4.11. Gradient Tree Boosting Algoritması

Gradyan ağaç artırma algoritması, diğer ağaç topluluğu öğrenme yöntemleriyle birlikte, endüstri ve veri madenciliği alanlarında yaygın olarak kullanılmaktadır. Girdilerin ölçeklendirmesinde değişmez ve özellikler arasında daha yüksek dereceli etkileşimi öğrenebilir. Diğer ağaç topluluğu yöntemlerinden farklı olarak, gradyan ağacı artırma ek bir şekilde eğitilir. Her t adımında, mevcut modelin kalıntısını en aza indirmek için başka bir ağaç yetiştir. Bu işlem (17)’de gösterilmiştir.

$$L^{(t)} = \sum_{i=1}^n I(y_i, \hat{y}^{t-1} + f_t(x_i)) + \Omega(f_t), \quad (17)$$

Burada l , i -inci y_i örneğinin etiketi ile son adımdaki mevcut ağaç çıktısı arasındaki farkı ölçen bir kayıp fonksiyonunu belirtir ve $\Omega(f_t)$, yeni ağacın karmaşıklığını cezalandıran düzenleme terimidir [120]. Gradient tree boosting yapısı Şekil 3.41’de gösterilmiştir.



Şekil 3.41. Gradient Tree Boosting yapısı.

Bu çalışmada Tablo 3.1’de belirtilen veri kümesi kullanılan Gradient tree boosting algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan Gradient tree boosting algoritmasının özellikleri:

- Kayıp fonksiyonu (loss): deviance
- Öğrenme oranı (learning_rate): 0.1

- İterasyon sayısı (n_estimators): 100
- Bölmenin kalitesini ölçme işlevi (criterion): friedman_mse
- Bir düğümü ayırmak için gereken minimum örnek sayısı (min_samples_split): 2
- Bir yaprak düğümünde olması gereken minimum örnek sayısı (min_samples_leaf): 1
- Maksimum derinlik (max_depth): 3
- Durdurma kriteri toleransı (tol): $1e - 4$

3.4.12. Pasif Agresif Sınıflandırma Algoritması

Pasif Agresif sınıflandırma algoritması (PAC), büyük ölçekli öğrenmeler için kullanılan bir algoritma türüdür. Yeni bir veri örneğini aldıktan sonra, modeli bu yeni örnek üzerinde düşük bir kayıp olacak şekilde günceller ve modelin mevcut olana yakın olduğundan emin olur [121]. PAC algoritması, doğrusal bir sınıflandırıcının çevrimiçi olarak eğitilmesi ve bunlar için bir kayıp fonksiyonu verildiğinde, çok sınıflı sınıflandırma, sıralama ve çoklu görev öğrenme dâhil olmak üzere birçok işe uygulanabilmektedir. Ayrıca, algoritma, ayrılabilir durumda sonlandırmayı ve tüm veri kümesinin işlenmesi boyunca kayıp fonksiyonunun toplamı için bir üst sınırlamayı garanti eder. Mevcut literatürdeki birçok PAC algoritması, aslında pasif agresif çerçevesinin temelini oluşturan prensipten ayrılmıştır; bu, alınan girdiyi doğru şekilde sınıflandırmak için yeterli ağırlık vektörünü güncellememiz gerektiğini belirtir. Kısaca, PAC algoritması ve Perceptron gibi öğrenici algoritmalar, çoklu sınıfların yapısını görmezden gelir ve problemi ikili bir sınıflandırmaya indirger [122].

Bu çalışmada Tablo 3.1'de belirtilen veri kümesi kullanılan PAC algoritması için Scikit-Learn kütüphanesinden yararlanılmıştır. En iyi sonucu bulmak için varsayılan parametrelerde değişiklikler yapılmıştır. Kullanılan PAC algoritmasının özellikleri:

- Maksimum adım boyutu (C): 1.0
- İterasyon sayısı (n_estimators): 1000
- Durdurma kriteri toleransı (tol): $1e - 3$

4. BULGULAR ve TARTIŞMA

Bu bölümde çalışma kapsamında tasarlanan akıllı ev sisteminde kullanılan yapay zekâ yöntemlerinin sonuç ve grafikleri verilmiştir. Yöntemlerin sınıflandırmadaki başarı oranlarını hesaplamak için (18), (19), (20), (21) ve (22)'deki formüller kullanılmıştır. Yöntemlerde hesaplanan sonuçlar, veri kümesindeki sütunların tek tek sınıflandırıldıktan sonra sınıflandırma sonuçlarının ortalamaları alınarak oluşturulmuştur.

$$Error\ rate = \frac{FP+FN}{TP+FP+FN+TN} \quad (18)$$

$$Precision = \frac{TP}{TP+FP} \quad (19)$$

$$Recall = \frac{TP}{TP+FN} \quad (20)$$

$$f1 - score = 2 * \frac{Recall*Precision}{Recall+Precision} \quad (21)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (22)$$

TP = True Pozitif (Doğru tahmin edilen artı sınıf), FP = False Pozitif (Yanlış tahmin edilen artı sınıf), FN = False Negatif (Yanlış tahmin edilen eksi sınıf) ve TN = True Negatif (Doğru tahmin edilen eksi sınıf)'dir. Recall duyarlılık, precision kesinlik, error rate hata oranı, accuracy doğruluk, macro avg makro ortalama, weighted avg ağırlıklı ortalama anlamına gelmektedir. F1-score, hassasiyet ve duyarlılığın ağırlıklı ortalaması olup, en iyi değeri 1 ve en kötü değeri 0'dır. Farklı algoritmaların probleme uygunluklarını gözlemlemek ve birbirleriyle performans karşılaştırılmasının yapılması için kalibrasyon grafikleri ve öğrenme eğrileri kullanılmıştır. Sınıflandırma işlemi yapılırken genellikle sadece sınıf etiketlerini tahmin etmenin yanı sıra ilgili etiketin bir olasılığı da hesaplanmaktadır. Bu olasılık geliştiricilere tahmin konusunda bir tür güven vermektedir. Bazı modeller sınıf olasılıkları hakkında kötü tahminler verebilirken bazıları olasılık tahminini desteklemez. Kalibrasyon grafikleri, belirli bir modelin olasılıklarının daha iyi kalibre edilmesini veya olasılık tahmini için destek eklenmesini sağlamaktadır.

4.1. Naive Bayes Modeller

4.1.1. Gaussian Naive Bayes

Gaussian Naive Bayes yöntemi sonucunda hesaplanan sınıflandırma raporu Tablo 4.1'de verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.92, 0.91, 0.91 ve 0.93, 0.93, 0.93'dür. Kesinlik değeri için makro ortalama 0.92 ve ağırlıklı ortalama ise 0.93 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.92 ve ağırlıklı ortalama ise 0.93 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.92 ve ağırlıklı ortalama 0.93 olarak hesaplanmıştır. Gaussian Naive Bayes yöntemi için hesaplanan başarı oranı 0.9168'dir. Tablo 4.2'de görüldüğü üzere Gaussian Naive Bayes yönteminde 2460 tane 0'dan 2237'si doğru, 223 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2530 tanesi doğru 207 tanesi yanlış sınıflandırılmıştır.

Tablo 4.1. Gaussian Naive Bayes sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.92	0.91	0.91
1	0.93	0.93	0.93
makro ortalama	0.92	0.92	0.92
ağırlıklı ortalama	0.93	0.93	0.93

Tablo 4.2. Gaussian Naive Bayes karmaşıklık matrisi.

	Gaussian Naive Bayes		Toplam
0	2237	223	2460
1	207	2503	2710
	0	1	

4.1.2. Bernoulli Naive Bayes

Bernoulli Naive Bayes yöntemi sonucunda hesaplanan sınıflandırma raporu Tablo 4.3'te verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.82, 0.88, 0.84 ve 0.84, 0.90, 0.86'dır. Kesinlik değeri için makro ortalama 0.83 ve ağırlıklı ortalama ise 0.83 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.89 ve ağırlıklı ortalama ise 0.89 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.85 ve ağırlıklı ortalama 0.85 olarak hesaplanmıştır. Bernoulli Naive Bayes yöntemi için hesaplanan başarı oranı 0.8646'dır. Tablo 4.4'te görüldüğü üzere Bernoulli Naive Bayes yöntemi 2460 tane

0'dan 2033'ünü doğru, 427 tanesini yanlış sınıflandırmıştır. 2710 tane 1'den 2437 tanesi doğru 273 tanesi yanlış sınıflandırılmıştır.

Tablo 4.3. Bernoulli Naive Bayes sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.82	0.88	0.84
1	0.84	0.90	0.86
makro ortalama	0.83	0.89	0.85
ağırlıklı ortalama	0.83	0.89	0.85

Tablo 4.4. Bernoulli Naive Bayes karmaşıklık matrisi.

	Bernoulli Naive Bayes		Toplam
0	2033	427	2460
1	273	2437	2710
	0	1	

4.1.3. Multinomial Naive Bayes

Multinomial Naive Bayes yöntemi sonucunda hesaplanan sınıflandırma raporu Tablo 4.5'te verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.93, 0.94, 0.93 ve 0.96, 0.96, 0.96'dır. Kesinlik değeri için makro ortalama 0.95 ve ağırlıklı ortalama ise 0.95 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.95 ve ağırlıklı ortalama ise 0.95 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.95 ve ağırlıklı ortalama 0.95 olarak hesaplanmıştır. Multinomial Naive Bayes yöntemi için hesaplanan başarı oranı 0.9427'dir. Tablo 4.6'da görüldüğü üzere Multinomial Naive Bayes yöntemi 2460 tane 0'dan 2297'sini doğru, 163 tanesini yanlış sınıflandırmıştır. 2710 tane 1'den 2577 tanesi doğru 133 tanesi yanlış sınıflandırılmıştır.

Tablo 4.5. Multinomial Naive Bayes sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.93	0.94	0.93
1	0.96	0.96	0.96
makro ortalama	0.95	0.95	0.95
ağırlıklı ortalama	0.95	0.95	0.95

Tablo 4.6. Multinomial Naive Bayes karmaşıklık matrisi.

	Multinomial Naive Bayes		Toplam
0	2297	163	2460
1	133	2577	2710
	0	1	

4.1.4. Complement Naive Bayes

Complement Naive Bayes yöntemi sonucunda hesaplanan sınıflandırma raporu Tablo 4.7'de verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.91, 0.91, 0.91 ve 0.94, 0.93, 0.94'tür. Kesinlik değeri için makro ortalama 0.93 ve ağırlıklı ortalama ise 0.93 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.92 ve ağırlıklı ortalama ise 0.92 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.93 ve ağırlıklı ortalama 0.93 olarak hesaplanmıştır. Complement Naive Bayes yöntemi için hesaplanan başarı oranı 0.9199'dur. Tablo 4.8'de görüldüğü üzere Complement Naive Bayes yöntemi 2460 tane 0'dan 2246'sını doğru, 214 tanesini yanlış sınıflandırmıştır. 2710 tane 1'den 2510 tanesi doğru 200 tanesi yanlış sınıflandırılmıştır.


Tablo 4.7. Complement Naive Bayes sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.91	0.91	0.91
1	0.94	0.93	0.94
makro ortalama	0.93	0.92	0.93
ağırlıklı ortalama	0.93	0.92	0.93

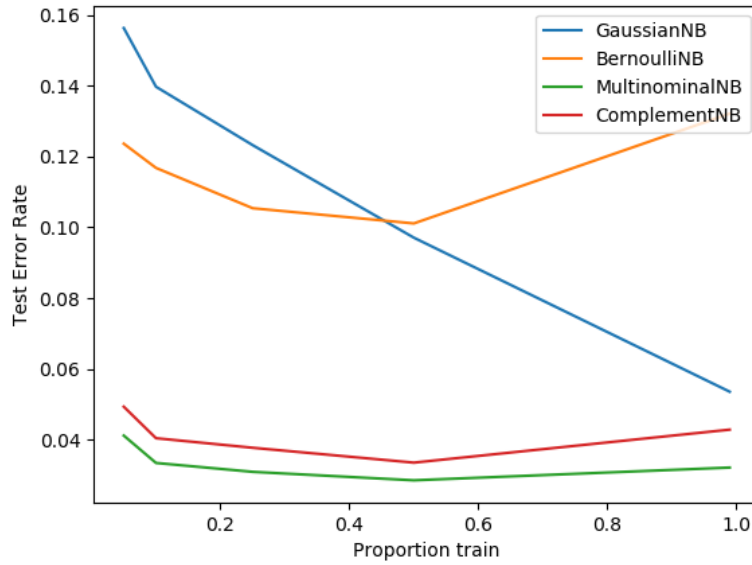
Tablo 4.8. Complement Naive Bayes karmaşıklık matrisi.

	Complement Naive Bayes		Toplam
0	2246	214	2460
1	200	2510	2710
	0	1	

Naive Bayes modellerinin kalibrasyon grafiği ve öğrenme eğrisi Şekil 4.1 ve 4.2'de gösterilmiştir. Kalibrasyon grafiğine göre referans çizgi üzerine daha yakın olan ve az dalgalanma yapan modeller sırasıyla; Multinomial, Complement, Gaussian ve Bernoulli Naive Bayes modelleridir. Modellerin öğrenme eğrisinde de görüldüğü üzere hata değeri en düşük olan model en başarılı olmuştur.



Şekil 4.1. Naive Bayes modellerinin kalibrasyon grafikleri (güvenilirlik eğrisi).



Şekil 4.2. Naive Bayes modellerinin öğrenme eğrisi.

4.2. Ensemble Modeller

4.2.1. Rassal Orman Algoritması

RF algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.9'da verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.96, 0.96, 0.96 ve 0.94, 0.95, 0.94'tür. Kesinlik değeri için makro ortalama 0.95 ve ağırlıklı

ortalama ise 0.95 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.96 ve ağırlıklı ortalama ise 0.96 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.95 ve ağırlıklı ortalama 0.95 olarak hesaplanmıştır. RF algoritması için hesaplanan başarı oranı 0.9653'dür. Tablo 4.10'da görüldüğü üzere RF algoritması yönteminde 2460 tane 0'dan 2368'i doğru, 92 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2623 tanesi doğru 87 tanesi yanlış sınıflandırılmıştır.

Tablo 4.9. RF algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.96	0.96	0.96
1	0.94	0.95	0.94
makro ortalama	0.95	0.96	0.95
ağırlıklı ortalama	0.95	0.96	0.95

Tablo 4.10. RF algoritması karmaşıklık matrisi.

	RF Algoritması		Toplam
0	2368	92	2460
1	87	2623	2710
	0	1	

4.2.2. Gradient Tree Boosting Algoritması

Gradient Tree Boosting algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.11'de verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.93, 0.94, 0.93 ve 0.94, 0.95, 0.94'tür. Kesinlik değeri için makro ortalama 0.93 ve ağırlıklı ortalama ise 0.93 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.94 ve ağırlıklı ortalama ise 0.94 olarak hesaplanmıştır. F1-score değeri makro ortalama 0.93 ve ağırlıklı ortalama 0.93 olarak hesaplanmıştır. Gradient Tree Boosting algoritması için hesaplanan başarı oranı 0.9439'dur. Tablo 4.12'de görüldüğü üzere Gradient Tree Boosting algoritması yönteminde 2460 tane 0'dan 2310'u doğru, 150 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2570 tanesi doğru 140 tanesi yanlış sınıflandırılmıştır.

Tablo 4.11. Gradient Tree Boosting algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.93	0.94	0.93
1	0.94	0.95	0.94
makro ortalama	0.93	0.94	0.93
ağırlıklı ortalama	0.93	0.94	0.93

Tablo 4.12. Gradient Tree Boosting algoritması karmaşıklık matrisi.

	Gradient Tree Boosting Algoritması		Toplam
0	2310	150	2460
1	140	2570	2710
	0	1	

4.2.3. XGBoost Algoritması

XGBoost algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.13'te verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.94, 0.95, 0.94 ve 0.95, 0.96, 0.95'tir. Kesinlik değeri için makro ortalama 0.94 ve ağırlıklı ortalama ise 0.94 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.95 ve ağırlıklı ortalama ise 0.95 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.94 ve ağırlıklı ortalama 0.94 olarak hesaplanmıştır. XGBoost algoritması için hesaplanan başarı oranı 0.9544'tür. Tablo 4.14'te görüldüğü üzere XGBoost algoritması yönteminde 2460 tane 0'dan 2239'u doğru, 121 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2600 tanesi doğru 110 tanesi yanlış sınıflandırılmıştır.



Tablo 4.13. XGBoost algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.94	0.95	0.94
1	0.95	0.96	0.95
makro ortalama	0.94	0.95	0.94
ağırlıklı ortalama	0.94	0.95	0.94

Tablo 4.14. XGBoost algoritması karmaşıklık matrisi.

	XGBoost Algoritması		Toplam
0	2239	121	2460
1	110	2600	2710
	0	1	

Ensemble modellerinin kalibrasyon grafiği ve öğrenme eğrisi Şekil 4.3 ve 4.4'te gösterilmiştir. Kalibrasyon grafiğine göre referans çizgi üzerine daha yakın olan ve az dalgalanma yapan algoritmalar sırasıyla; RF, Gradient Tree Boosting ve XGBoost algoritmalarıdır. Modellerin öğrenme eğrisinde de görüldüğü üzere hata değeri en düşük olan model en başarılı olmuştur.

**Şekil 4.3.** Ensemble modellerinin kalibrasyon grafikleri (güvenilirlik eğrisi).**Şekil 4.4.** Ensemble modellerinin öğrenme eğrisi.

4.3. Genel Linear Modeller

4.3.1. Lojistik Regresyon Algoritması

LR algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.15'te verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.96, 0.95, 0.95 ve 0.95, 0.94, 0.94'tür. Kesinlik değeri için makro ortalama 0.95 ve ağırlıklı ortalama ise 0.95 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.94 ve ağırlıklı ortalama ise 0.94 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.94 ve ağırlıklı ortalama 0.94 olarak hesaplanmıştır. LR algoritması için hesaplanan başarı oranı 0.9621'dir. Tablo 4.16'da görüldüğü üzere LR algoritması yönteminde 2460 tane 0'dan 2270'i doğru, 90 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2608 tanesi doğru 102 tanesi yanlış sınıflandırılmıştır.

Tablo 4.15. LR algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.96	0.95	0.95
1	0.95	0.94	0.94
makro ortalama	0.95	0.94	0.94
ağırlıklı ortalama	0.95	0.94	0.94

Tablo 4.16. LR algoritması karmaşıklık matrisi.

	LR Algoritması		Toplam
0	2270	90	2460
1	102	2608	2710
	0	1	

4.3.2. Stochastic Gradient Descent Algoritması

SGD algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.17'de verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.97, 0.96, 0.96 ve 0.95, 0.96, 0.95'tir. Kesinlik değeri için makro ortalama 0.96 ve ağırlıklı ortalama ise 0.96 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.96 ve ağırlıklı ortalama ise 0.96 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.95 ve ağırlıklı ortalama 0.95 olarak hesaplanmıştır. SGD algoritması için hesaplanan başarı oranı 0.9651'dir. Tablo 4.18'de görüldüğü üzere SGD algoritması yönteminde 2460 tane 0'dan 2381'i doğru, 79 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2609 tanesi doğru 101 tanesi yanlış sınıflandırılmıştır.

Tablo 4.17. SGD algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.97	0.96	0.96
1	0.95	0.96	0.95
makro ortalama	0.96	0.96	0.95
ağırlıklı ortalama	0.96	0.96	0.95

Tablo 4.18. SGD algoritması karmaşıklık matrisi.

	SGD Algoritması		Toplam
0	2381	79	2460
1	101	2609	2710
	0	1	

4.3.3. Pasif Agresif Sınıflandırma Algoritması

PAC sınıflandırma algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.19'da verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.94, 0.93, 0.93 ve 0.92, 0.94, 0.93'tür. Kesinlik değeri için makro ortalama 0.93 ve ağırlıklı ortalama ise 0.93 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.93 ve ağırlıklı ortalama ise 0.93 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.93 ve ağırlıklı ortalama 0.93 olarak hesaplanmıştır. PAC algoritması için hesaplanan başarı oranı 0.9442'dir. Tablo 4.20'de görüldüğü üzere PAC algoritması yönteminde 2460 tane 0'dan 2322'si doğru, 138 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2560 tanesi doğru 150 tanesi yanlış sınıflandırılmıştır.



Tablo 4.19. PAC algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.94	0.93	0.93
1	0.92	0.94	0.93
makro ortalama	0.93	0.93	0.93
ağırlıklı ortalama	0.93	0.93	0.93

Tablo 4.20. PAC algoritması karmaşıklık matrisi.

	PAC Algoritması		Toplam
0	2322	138	2460
1	150	2560	2710
	0	1	

Genel Linear modellerinin kalibrasyon grafiği ve öğrenme eğrisi Şekil 4.5 ve 4.6'da gösterilmiştir. Kalibrasyon grafiğine göre referans çizgi üzerine daha yakın olan ve az dalgalanma yapan algoritmalar sırasıyla; SGD, LR ve PAC algoritmalarıdır. Modellerin öğrenme eğrisinde de görüldüğü üzere hata değeri en düşük olan model en başarılı olmuştur.

**Şekil 4.5.** Genel linear modellerinin kalibrasyon grafikleri (güvenilirlik eğrisi).**Şekil 4.6.** Genel linear modellerinin öğrenme eğrisi.

4.4. Karar Ağacı Modeli

Karar ağacı algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.21’de verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.96, 0.95, 0.95 ve 0.95, 0.93, 0.94’tür. Kesinlik değeri için makro ortalama 0.95 ve ağırlıklı ortalama ise 0.95 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.94 ve ağırlıklı ortalama ise 0.94 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.94 ve ağırlıklı ortalama 0.94 olarak hesaplanmıştır. Karar ağacı algoritması için hesaplanan başarı oranı 0.9609’dur. Tablo 4.22’de görüldüğü üzere Karar ağacı algoritması yönteminde 2460 tane 0’dan 2378’i doğru, 82 tanesi yanlış sınıflandırılmıştır. 2710 tane 1’den 2590 tanesi doğru 120 tanesi yanlış sınıflandırılmıştır.


Tablo 4.21. Karar ağacı algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.96	0.95	0.95
1	0.95	0.93	0.94
makro ortalama	0.95	0.94	0.94
ağırlıklı ortalama	0.95	0.94	0.94

Tablo 4.22. Karar ağacı algoritması karmaşıklık matrisi.

	Karar Ağacı Algoritması		Toplam
0	2378	82	2460
1	120	2590	2710
	0	1	

Karar ağacı algoritmasının öğrenme eğrisi Şekil 4.7’de gösterilmiştir. Öğrenme eğrisi algoritmanın problemde başarılı sonuç verdiğini göstermektedir.



Şekil 4.7. Karar ağacı modelinin öğrenme eğrisi.

4.5. Destek Vektör Makinesi Modeli

SVM algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.23'te verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.93, 0.91, 0.92 ve 0.94, 0.93, 0.93'tür. Kesinlik değeri için makro ortalama 0.93 ve ağırlıklı ortalama ise 0.93 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.92 ve ağırlıklı ortalama ise 0.92 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.92 ve ağırlıklı ortalama 0.92 olarak hesaplanmıştır. SVM algoritması için hesaplanan başarı oranı 0.9239'dur. Tablo 4.24'te görüldüğü üzere SVM algoritması yönteminde 2460 tane 0'dan 2290'ı doğru, 170 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2487 tanesi doğru 223 tanesi yanlış sınıflandırılmıştır.


Tablo 4.23. SVM algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.93	0.91	0.92
1	0.94	0.93	0.93
makro ortalama	0.93	0.92	0.92
ağırlıklı ortalama	0.93	0.92	0.92

Tablo 4.24. SVM algoritması karmaşıklık matrisi.

	SVM Algoritması		Toplam
0	2290	170	2460
1	223	2487	2710
	0	1	

SVM algoritmasının öğrenme eğrisi Şekil 4.8'de gösterilmiştir. Öğrenme eğrisi algoritmanın problemde başarılı sonuç verdiğini göstermektedir.

**Şekil 4.8.** SVM modelinin öğrenme eğrisi.

4.6. K-En Yakın Komşu Modeli

KNN algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.25'te verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.91, 0.90, 0.90 ve 0.93, 0.92, 0.92'dir. Kesinlik değeri için makro ortalama 0.92 ve ağırlıklı ortalama ise 0.92 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.91 ve ağırlıklı ortalama ise 0.91 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.91 ve ağırlıklı ortalama 0.91 olarak hesaplanmıştır. KNN algoritması için hesaplanan başarı oranı 0.9117'dir. Tablo 4.26'da görüldüğü üzere KNN Algoritması yönteminde 2460 tane 0'dan 2250'si doğru, 210 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2464 tanesi doğru 246 tanesi yanlış sınıflandırılmıştır.


Tablo 4.25. KNN algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.91	0.90	0.90
1	0.93	0.92	0.92
makro ortalama	0.92	0.91	0.91
ağırlıklı ortalama	0.92	0.91	0.91

Tablo 4.26. KNN algoritması karmaşıklık matrisi.

	KNN Algoritması		Toplam
0	2250	210	2460
1	246	2464	2710
	0	1	

KNN algoritmasının öğrenme eğrisi Şekil 4.9'da gösterilmiştir. Öğrenme eğrisi algoritmanın problemde başarılı sonuç verdiğini göstermektedir.

**Şekil 4.9.** KNN modelinin öğrenme eğrisi.

4.7. Gaussian Süreç Modeli

GPC algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.27'de verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.97, 0.98, 0.97 ve 0.98, 0.98, 0.98'dir. Kesinlik değeri için makro ortalama 0.97 ve ağırlıklı ortalama ise 0.97 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.98 ve ağırlıklı

ortalama ise 0.98 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.97 ve ağırlıklı ortalama 0.97 olarak hesaplanmıştır. GPC algoritması için hesaplanan başarı oranı 0.9794'tür. Tablo 4.28'de görüldüğü üzere GPC algoritması yönteminde 2460 tane 0'dan 2403'ü doğru, 57 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2661 tanesi doğru 49 tanesi yanlış sınıflandırılmıştır.


Tablo 4.27. GPC algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.97	0.98	0.97
1	0.98	0.98	0.98
makro ortalama	0.97	0.98	0.97
ağırlıklı ortalama	0.97	0.98	0.97

Tablo 4.28. GPC algoritması karmaşıklık matrisi.

	GPC Algoritması		Toplam
	0	1	
0	2403	57	2460
1	49	2661	2710

GPC algoritmasının öğrenme eğrisi Şekil 4.10'da gösterilmiştir. Öğrenme eğrisi algoritmanın problemde başarılı sonuç verdiğini göstermektedir.



Şekil 4.10. GPC modelinin öğrenme eğrisi.

4.8. Yapay Sinir Ağı Modeli

MLP algoritması sonucunda hesaplanan sınıflandırma raporu Tablo 4.29'da verilmiştir. Sınıflandırma raporuna göre 0 ve 1 sınıfları için kesinlik, duyarlılık ve f1-score değerleri sırasıyla; 0.94, 0.93, 0.93 ve 0.95, 0.94, 0.94'tür. Kesinlik değeri için makro ortalama 0.94 ve ağırlıklı ortalama ise 0.94 olarak hesaplanmıştır. Duyarlılık değeri için makro ortalama 0.93 ve ağırlıklı ortalama ise 0.93 olarak hesaplanmıştır. F1-score değeri için makro ortalama 0.93 ve ağırlıklı ortalama 0.93 olarak hesaplanmıştır. MLP algoritması için hesaplanan başarı oranı 0.9442'dir. Tablo 4.30'da görüldüğü üzere MLP algoritması yönteminde 2460 tane 0'dan 2335'i doğru, 125 tanesi yanlış sınıflandırılmıştır. 2710 tane 1'den 2547 tanesi doğru 163 tanesi yanlış sınıflandırılmıştır.


Tablo 4.29. MLP algoritması sınıflandırma raporu.

	Kesinlik	Duyarlılık	f1-score
0	0.94	0.93	0.93
1	0.95	0.94	0.94
makro ortalama	0.94	0.93	0.93
ağırlıklı ortalama	0.94	0.93	0.93

Tablo 4.30. MLP algoritması karmaşıklık matrisi.

	MLP Algoritması		Toplam
0	2335	125	2460
1	163	2547	2710
	0	1	

MLP algoritmasının öğrenme eğrisi Şekil 4.11'de gösterilmiştir. Öğrenme eğrisi algoritmanın problemde başarılı sonuç verdiğini göstermektedir.



Şekil 4.11. MLP modelinin öğrenme eğrisi.



5. SONUÇLAR ve ÖNERİLER

Bu tezde, Raspberry Pi ve Arduino kullanarak çeşitli sensör ve komponentlerle çalışan, yapay zekâ tabanlı bir akıllı ev sistemi sunulmuştur. Çalışmanın temel amacı, insanların hayatlarını kolaylaştırmak, güvenliklerini sağlamak, olası kazaları önceden algılayarak felaketleri önlemek ve teknolojiyi hayatımıza pozitif etkiler bırakacak şekilde entegre etmektir. Bu çalışmayı benzerlerinden ayıran nokta, daha önce geliştirilen uzaktan kontrollü akıllı ev sistemlerinin aksine, öğrenebilen ve bazı aktiviteleri ev sakinleri yararına otonom olarak yapabilen bir sistem olmasıdır. Aynı zamanda çalışmanın dikkat çeken bir yönü de, literatürde kullanılmayan birçok yapay zekâ algoritmasının sistem üzerinde denenmesi ve elde edilen sonuçların birbirleriyle karşılaştırılmasıdır. Geliştirilen sistemde birçok farklı teknoloji, güncel bağlantı ve kontrol protokolleri de kullanılmaktadır.

Sistem sıradan akıllı evlerde olduğu gibi hem ev içinden hem de uzaktan yönetilebilmektedir. Aynı zamanda evde kimse olmadığı durumlarda birçok güvenlik sistemi eş zamanlı olarak çalışmakta ve evin güvenliğini sağlamaktadır. Birçok farklı teknolojinin kullanıldığı bu yapı sadece bir ev sistemi olarak değil, çeşitli çalışma ve ofis ortamlarında da uyumlu bir şekilde kullanılabilir. Sistemin donanım altyapısında RPi ve Arduino Nano mikrodenetleyicileri bulunmaktadır. Sistemin dış dünya ile etkileşime geçebilmesi için birçok sensör kullanılmıştır. Bu sensörler; LDR, alev algılama sensörü, MQ5 yanıcı gaz algılama sensörü, elektrikli aletleri kontrol edebilmek için röle modülleri, yağmur algılama sensörü, ses sensörü, DHT11 sıcaklık ve nem sensörü, PIR sensörü, kamera modülü, GSM modülü ve fan modülüdür. Geliştirilen sistemin Bluetooth kontrol modu, otonom kontrol ve güvenlik modu ve web kontrol modu olmak üzere 3 temel modu vardır. Bluetooth kontrol modunda ev sakinleri tasarlanan Android uygulamasıyla evin kontrolünü sağlayabilmektedir. Otonom kontrol ve güvenlik modu ev içerisinde kimse olmadığı zaman devreye giren sistemdir. Web kontrol modunda kullanıcıların evden uzakta olduğu durumlarda internet bağlantısı ile web sayfasından akıllı ev sistemlerini izleyebilmekte ve kontrol edebilmektedir.

Tasarlanan sistemin bir prototipi yapılmış ve test edilmiştir. Testler sonucunda sistemde bulunan kontrol ve güvenlik sistemlerinin başarılı sonuçlar verdiği gözlemlenmiştir. Çalışmada kullanılan veri kümesi, sistemin günlük kullanımı sonucunda sensörlerden alınan verilerden ve ek olarak girilen sanal verilerden oluşmaktadır. Veri kümesini yapay zekâ algoritmaları ile test etmeden önce veriler kontrol edilerek sensör dalgalanmalarından dolayı oluşan yanlış değerler çıkarılmıştır. Daha sonra veri kümesine normalizasyon işlemi yapılmıştır. Çalışmada yapay zekâ algoritmaları olarak; LR, KNN, SVM, Karar ağaçları, XGBoost, MLP, RF, SGD, GPC, PAC algoritmaları ile Gaussian, Bernoulli, Multinomial ve Complement Naive Bayes algoritmaları kullanılmıştır. Kullanılan algoritmalar kategorik olarak birbirleriyle karşılaştırılmış ve sonuçlar gözlemlenmiştir. Çalışmada kullanılan yapay zekâ algoritmalarından en başarılı sonuçları, 0.9794

başarı oranı ile GPC algoritması, 0.9653 başarı oranı ile RF algoritması ve 0.9651 başarı oranı ile SGD algoritması elde etmiştir.

Çalışmada kullanılan sensör ve bileşenler yerine daha gelişmiş, hızlı ve güvenilirliği yüksek ürünler kullanıldığı takdirde, tasarlanan akıllı ev sisteminin daha başarılı ve istikrarlı bir düzeye çıkarılabileceği gözlemlenmiştir. Elde edilen başarılı sonuçlar, mevcut yöntemlerin iyileştirilebileceğini ve farklı yöntemler kullanılarak daha iyi sonuçlar alınabileceğini göstermektedir.



KAYNAKLAR

- [1]. İnal, K., Akçayol, M. A. (2009). Gsm tabanlı akıllı ev uygulaması. *Bilişim Teknolojileri Dergisi*, 2(2).
- [2]. Jose, A. C., Malekian, R. (2015). Smart home automation security: a literature review. *SmartCR*, 5(4), 269-285.
- [3]. Kadam, R., Mahamuni, P., Parikh, Y. (2015). Smart home system. *International Journal of Innovative research in Advanced Engineering (IJIRAE)*, 2(1).
- [4]. Al-Sarawi, S., Anbar, M., Alieyan, K., Alzubaidi, M. (2017, May). Internet of Things (IoT) communication protocols. In *2017 8th International conference on information technology (ICIT)* (pp. 685-690). IEEE.
- [5]. Yıldız, A. (2018). Endüstri 4.0 ve akıllı fabrikalar. *Sakarya University Journal of Science*, 22(2), 546-556.
- [6]. Marjani, M., Nasaruddin, F., Gani, A., Karim, A., Hashem, I. A. T., Siddiqa, A., Yaqoob, I. (2017). Big IoT data analytics: architecture, opportunities, and open research challenges. *IEEE Access*, 5, 5247-5261.
- [7]. Liu, C., Yang, C., Zhang, X., Chen, J. (2015). External integrity verification for outsourced big data in cloud and IoT: A big picture. *Future generation computer systems*, 49, 58-67.
- [8]. Singh, K. J., Kapoor, D. S. (2017). Create Your Own Internet of Things: A survey of IoT platforms. *IEEE Consumer Electronics Magazine*, 6(2), 57-68.
- [9]. Güğül, G. N., Sarıtaş, M. (2011). Akıllı ev sistemleri ve uygulaması. *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, (025), 49-60.
- [10]. Aslan, A. (2014). *Akıllı ev kavramı ve otomasyon sistemleri* (Doctoral dissertation, Lisansüstü Eğitim Enstitüsü), Haliç Üniversitesi, İstanbul.
- [11]. Sriskanthan, N., Tan, F., Karande, A. (2002). Bluetooth based home automation system. *Microprocessors and microsystems*, 26(6), 281-289.
- [12]. Naresh, D., Chakradhar, B., Krishnaveni, S. (2013). Bluetooth based home automation and security system using ARM9. *International Journal of Engineering Trends and Technology (IJETT)*, 4(9), 4051-4058.
- [13]. Asadullah, M., Ullah, K. (2017, April). Smart home automation system using Bluetooth technology. In *2017 International Conference on Innovations in Electrical Engineering and Computational Technologies (ICIEECT)* (pp. 1-6). IEEE.
- [14]. Yan, M., Shi, H. (2013). Smart living using Bluetooth-based Android smartphone. *International journal of wireless and mobile networks*, 5(1), 65.
- [15]. Collotta, M., Pau, G. (2015). A solution based on bluetooth low energy for smart home energy management. *Energies*, 8(10), 11916-11938.
- [16]. Javale, D., Mohsin, M., Nandanwar, S., Shingate, M. (2013). Home automation and security system using Android ADK. *International journal of electronics communication and computer*

technology (IJECCT), 3(2), 382-385.

[17]. Pandya, B., Mehta, M., Jain, N., Kadam, S. (2016). Android based home automation system using Bluetooth and voice command. *International Research Journal of Engineering and Technology (IRJET)*, 3(04), 1337-1342.

[18]. Hisham, A. B., Ishak, M. I., Teik, C. K., Mohamed, Z., Idris, N. H. (2014). Bluetooth-based home automation system using an android phone. *Jurnal Teknologi (Sciences and Engineering)*, 70(3), 57-61.

[19]. Potts, J., Sukittanon, S. (2012, March). Exploiting Bluetooth on Android mobile devices for home security application. In *2012 Proceedings of IEEE Southeastcon* (pp. 1-4). IEEE.

[20]. Garlapati, T. S., Lakshmi, P. S. H. S. (2015). Smart home automated control system using Bluetooth based on solar panel. *International Journal of Science, Engineering and Technology Research (IJSETR)*, 4(11), 3953-3955.

[21]. Amin, M. S., Jalil, J., Reaz, M. B. I. (2012, May). Accident detection and reporting system using GPS, GPRS and GSM technology. In *2012 International Conference on Informatics, Electronics and Vision (ICIEV)* (pp. 640-643). IEEE.

[22]. Kardaş, Y. Y., Özerdem, M. S. (2015). Gsm kontrollü akıllı ev uygulaması. *DÜMF Mühendislik Dergisi*, 6(1), 9-18.

[23]. Huang, H., Xiao, S., Meng, X., Xiong, Y. (2010, April). A remote home security system based on wireless sensor network and GSM technology. In *2010 Second International Conference on Networks Security, Wireless Communications and Trusted Computing* (Vol. 1, pp. 535-538). IEEE.

[24]. Can, M. S., Turan, B., Arı, Y. S., Ağca, A. (2013, September) Evler ve soğuk hava depoları için sms ve mikrodenetleyici tabanlı buzdolabı-soğutucu arıza uyarı sistemi. In *Otomatik Kontrol Ulusal Toplantısı (TOK2013)* (pp. 68-71).

[25]. Ocak, F., Gökrem, L. (2015). Arduino ve PC tabanlı güvenlik sistemi prototipi tasarımı. *Journal of New Results in Engineering and Natural Sciences*, (4), 11-24.

[26]. Teymourzadeh, R., Ahmed, S. A., Chan, K. W., Hoong, M. V. (2013, December). Smart gsm based home automation system. In *2013 IEEE Conference on Systems, Process & Control (ICSPC)* (pp. 306-309). IEEE.

[27]. Jivani, M. N. (2014). GSM based home automation system using app-inventor for android mobile phone. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 3(9).

[28]. Hasan, R., Khan, M. M., Ashek, A., Rumpa, I. J. (2015). Microcontroller based home security system with GSM technology. *Open Journal of Safety Science and Technology*, 5(02), 55.

[29]. Singh, A., Pal, A., Rai, B. (2015). GSM based home automation, safety and security system using Android mobile phone. *International Journal of Engineering Research and Technology (IJERT)*, 4(05).

[30]. Rana, G. S. M., Khan, A. A. M., Hoque, M. N., Mitul, A. F. (2013, December). Design and implementation of a GSM based remote home security and appliance control system. In *2013 2nd International Conference on Advances in Electrical Engineering (ICAEE)* (pp. 291-295). IEEE.

- [31]. Choudhury, B., Choudhury, T. S., Pramanik, A., Arif, W., Mehedi, J. (2015, March). Design and implementation of an SMS based home security system. In *2015 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)* (pp. 1-7). IEEE.
- [32]. Parab, A. S., Joglekar, A. (2015). Implementation of home security system using GSM module and microcontroller. *International Journal of Computer Science and Information Technologies*, 6(3), 2950-2953.
- [33]. Adhya, S., Saha, D., Das, A., Jana, J., Saha, H. (2016, January). An IoT based smart solar photovoltaic remote monitoring and control unit. In *2016 2nd international conference on control, instrumentation, energy and communication (CIEC)* (pp. 432-436). IEEE.
- [34]. Lee, I., Lee, K. (2015). The Internet of Things (IoT): Applications, investments, and challenges for enterprises. *Business Horizons*, 58(4), 431-440.
- [35]. Torğul, B., Şağbaşı, L., Balo, F. (2016). Internet of Things: a survey. *International Journal of Applied Mathematics, Electronics and Computers*, 4, 104-110.
- [36]. Bingol, O., Tasdelen, K., Keskin, Z., Kocaturk, Y. E. (2014). Web-based smart home automation: PLC-controlled implementation. *Acta Polytechnica Hungarica*, 11(3), 51-63.
- [37]. Kumar, S., Lee, S. R. (2014, June). Android based smart home system with control via Bluetooth and internet connectivity. In *The 18th IEEE International Symposium on Consumer Electronics (ISCE 2014)* (pp. 1-2). IEEE.
- [38]. Baytürk, M., Çetin, G., Çetin, A. (2013). Gömülü sunucu ile tasarlanmış internet tabanlı sera otomasyon sistemi uygulaması. *Bilişim Teknolojileri Dergisi*, 6(2), 53.
- [39]. Ramli, M. I., Wahab, A., Helmy, M., Ahmad, N. (2006). Towards smart home: control electrical devices online. *International Conference on Science and Technology: Application in Industry and Education*
- [40]. Chandramohan, J., Nagarajan, R., Satheeshkumar, K., Ajithkumar, N., Gopinath, P. A., Ranjithkumar, S. (2017). Intelligent smart home automation and security system using Arduino and Wi-fi. *International Journal of Engineering And Computer Science (IJECS)*, 6(3), 20694-20698.
- [41]. Khan, A. A., Mouftah, H. T. (2011, September). Web services for indoor energy management in a smart grid environment. In *2011 IEEE 22nd International Symposium on Personal, Indoor and Mobile Radio Communications* (pp. 1036-1040). IEEE.
- [42]. Yüzgeç, U., Ömer, A. B. A. (2017). Raspberry Pi kullanılarak bir akıllı ev uygulaması geliştirilmesi. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 4(1), 21-29.
- [43]. Ramya, C. M., Shanmugaraj, M., Prabaharan, R. (2011, April). Study on ZigBee technology. In *2011 3rd International Conference on Electronics Computer Technology* (Vol. 6, pp. 297-301). IEEE.
- [44]. Ahamed, S. S. (2009). The role of Zigbee technology in future data communication system. *Journal of Theoretical & Applied Information Technology*, 5(2).
- [45]. Hou, J., Wu, C., Yuan, Z., Tan, J., Wang, Q., Zhou, Y. (2008, December). Research of intelligent home security surveillance system based on zigbee. In *2008 International Symposium on Intelligent Information Technology Application Workshops* (pp. 554-557). IEEE.
- [46]. Liu, Z. Y. (2014). Hardware design of smart home system based on ZigBee wireless sensor

network. *Aasri Procedia*, 8, 75-81.

[47]. Liang, L., Huang, L., Jiang, X., Yao, Y. (2008, May). Design and implementation of wireless smart-home sensor network based on ZigBee protocol. In *2008 International Conference on Communications, Circuits and Systems* (pp. 434-438). IEEE.

[48]. Dagtas, S., Pekhteryev, G., Sahinoglu, Z. (2007, May). Multi-stage real time health monitoring via ZigBee in smart homes. In *21st International Conference on Advanced Information Networking and Applications Workshops (AINAW'07)* (Vol. 2, pp. 782-786). IEEE.

[49]. Krishna, Y. B., Nagendram, S. (2012). Zigbee based voice control system for smart home. *International Journal on Computer Technology and Applications*, 3(1), 163-168.

[50]. Al-Ali, A. R., Qasaimeh, M., Al-Mardini, M., Radder, S., Zualkernan, I. A. (2015, February). ZigBee-based irrigation system for home gardens. In *2015 International Conference on Communications, Signal Processing, and their Applications (ICCSPA'15)* (pp. 1-5). IEEE.

[51]. Doondeok-dong, Y. (2013). The implementation of smart home system based on 3G and ZigBee in wireless network systems. *International journal of smart home*, 7(3).

[52]. Siddiqui, A. A., Ahmad, A. W., Yang, H. K., Lee, C. (2012, February). ZigBee based energy efficient outdoor lighting control system. In *2012 14th International Conference on Advanced Communication Technology (ICACT)* (pp. 916-919). IEEE.

[53]. Malhi, K., Mukhopadhyay, S. C., Schnepfer, J., Haefke, M., Ewald, H. (2010). A zigbee-based wearable physiological parameters monitoring system. *IEEE sensors journal*, 12(3), 423-430.

[54]. Leccese, F., Cagnetti, M., Trinca, D. (2014). A smart city application: A fully controlled street lighting isle based on Raspberry-Pi card, a ZigBee sensor network and WiMAX. *Sensors*, 14(12), 24408-24424.

[55]. Becker, E., Metsis, V., Arora, R., Vinjumur, J., Xu, Y., Makedon, F. (2009, June). SmartDrawer: RFID-based smart medicine drawer for assistive environments. In *Proceedings of the 2nd international Conference on Pervasive Technologies Related to Assistive environments* (p. 49). ACM.

[56]. Jia, X., Feng, Q., Fan, T., Lei, Q. (2012, April). RFID technology and its applications in Internet of Things (IoT). In *2012 2nd international conference on consumer electronics, communications and networks (CECNet)* (pp. 1282-1285). IEEE.

[57]. Nainan, S., Parekh, R., Shah, T. (2013). RFID technology based attendance management system. *arXiv preprint arXiv:1306.5381*.

[58]. Ali, Z., Sonkusare, R. (2013). Rfid based smart shopping and billing. *International Journal of Advanced Research in Computer and Communication Engineering*, 2(12), 4696-4699.

[59]. Mainetti, L., Palano, L., Patrono, L., Stefanizzi, M. L., Vergallo, R. (2014, September). Integration of RFID and WSN technologies in a Smart Parking System. In *SoftCOM* (pp. 104-110).

[60]. Yao, W., Chu, C. H., Li, Z. (2011). Leveraging complex event processing for smart hospitals using RFID. *Journal of Network and Computer Applications*, 34(3), 799-810.

[61]. Russell, S. J., Norvig, P. (2016). *Artificial intelligence: a modern approach*. Malaysia: Pearson Education Limited.

- [62]. Hussein, A., Adda, M., Atieh, M., Fahs, W. (2014). Smart home design for disabled people based on neural networks. *Procedia Computer Science*, 37, 117-126.
- [63]. Pathak, A. K., Chatterji, D. S., Narkhede, M. S. (2012). Artificial intelligence based optimization algorithm for demand response management of residential load in smart grid. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(4).
- [64]. Basnayake, B. A. D. J. C. K., Amarasinghe, Y. W. R., Attalage, R. A., Udayanga, T. D. I., Jayasekara, A. G. B. P. (2015). Artificial intelligence based smart building automation controller for energy efficiency improvements in existing buildings. *International Journal of Advanced Automation Science and Technology*, 40(40).
- [65]. Chamoso, P., De La Prieta, F. (2015). Swarm-based smart city platform: a traffic application. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 4(2), 89-98.
- [66]. Güneş, H. (2016). *Öğrenebilen, web tabanlı, düşük enerji tüketimli, modüler ev otomasyon sistemi geliştirilmesi*. Balıkesir Üniversitesi, Balıkesir.
- [67]. Süzen, A. A., Taşdelen, K. (2012). Kinect Teknolojisi Kullanılarak Engelliler İçin Ev Otomasyonu. *Uluslararası Teknolojik Bilimler Dergisi*, 5(2), 122-131.
- [68]. Rodriguez, J. D., Perez, A., Lozano, J. A. (2009). Sensitivity analysis of k-fold cross validation in prediction error estimation. *IEEE transactions on pattern analysis and machine intelligence*, 32(3), 569-575.
- [70]. Arduino, *Arduino Nano*, 20 Kasım 2019 tarihinde <https://store.arduino.cc/usa/arduino-nano> adresinden erişildi.
- [71]. Zhao, C. W., Jegatheesan, J., Loon, S. C. (2015). Exploring iot application using raspberry pi. *International Journal of Computer Networks and Applications*, 2(1), 27-34.
- [72]. Raspberry Pi, *Raspberry Pi 3 Model B+*, 20 Kasım 2019 tarihinde <https://www.raspberrypi.org/products/raspberry-pi-3-model-b-plus/> adresinden erişildi.
- [73]. Robotistan, *LDR Sensör*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/5mm-ldr> adresinden erişildi.
- [74]. Robotistan, *Flame Sensör*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/ates-algilayici-sensor-karti-flamesensor> adresinden erişildi.
- [75]. Robotistan, *MQ5 Gaz Sensör*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/lpgpropan-gaz-sensor-karti-mq5> adresinden erişildi.
- [76]. Robotistan, *Çift Kanallı Röle*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/2-way-12v-relay-module-2li-12v-role-karti> adresinden erişildi.
- [77]. Robotistan, *Yağmur Sensör*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/yagmur-sensoru-rain-sensor> adresinden erişildi.
- [78]. Robolink Teknoloji, *Ses Sensör*, 20 Kasım 2019 tarihinde <https://www.robolinkmarket.com/ses-sensoru.html> adresinden erişildi.
- [79]. Robotistan, *DHT11 Sıcaklık ve Nem Sensör*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/dht11-isi-ve-nem-sensoru-kart> adresinden erişildi.

- [80]. Robotistan, *PIR Sensör*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/hc-sr501-ayarlanabilir-ir-hareket-algilama-sensoru-pir> adresinden erişildi.
- [81]. Robotistan, *Raspberry Pi Kamera Modülü*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/raspberry-pi-kamera-modulu-camera> adresinden erişildi.
- [82]. Robotistan, *L9110 Sürücülü Motor Fan Modülü*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/l9110-suruculu-motor-ve-fan-modulu> adresinden erişildi.
- [83]. Robotistan, *Servo Motor*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/tower-prosg90-rc-mini-servo-motor> adresinden erişildi.
- [84]. Robo Market, *SIM800 GSM GPRS Modülü*, 20 Kasım 2019 tarihinde <https://www.robomarket.com.tr/sim800-serisi-arduino-gsm-gprs-modulu-simcom-sim800l-modulu/> adresinden erişildi.
- [85]. Robotistan, *LM2596 Voltaj Regülatörü*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/ayarlanabilir-3a-voltaj-regulator-karti-lm2596-adj> adresinden erişildi.
- [86]. Robotistan, *MCP3008*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/mcp3008-8-kanal-10-bit-adc> adresinden erişildi.
- [87]. Robit Shop, *Raspberry Pi 3/2/B+/A+ GPIO-Breadboard Kartı + Raspberry Pi 3/2/B+/A+ 40'lı GPIO Çoklu Kablo (Ribbon)*, 20 Kasım 2019 tarihinde <https://www.robishop.com/urun/raspberry-pi-3-2-b-a-gpio-breadboard-karti-1> adresinden erişildi.
- [88]. Robotistan, *Breadboard*, 20 Kasım 2019 tarihinde <https://www.robotistan.com/breadboard-2> adresinden erişildi.
- [89]. Scikit-Learn, *About Us*, 21 Kasım 2019 tarihinde <https://scikit-learn.org/stable/about.html#infrastructure-support> adresinden erişildi.
- [90]. Scikit-Learn, *Choosing the Right Estimator*, 21 Kasım 2019 tarihinde https://scikit-learn.org/stable/tutorial/machine_learning_map/index.html adresinden erişildi.
- [91]. Çokluk, Ö. (2010). Lojistik regresyon analizi: Kavram ve uygulama. *Kuram ve Uygulamada Eğitim Bilimleri*, 10(3), 1357-1407.
- [92]. Gök, A. C., Özdemir, A. (2011). Lojistik regresyon analizi ile banka sektör paylarının tahminlenmesi. *Dokuz Eylül Üniversitesi İşletme Fakültesi Dergisi*, 12(1), 43-51.
- [93]. Phillips, J., Cripps, E., Lau, J. W., Hodkiewicz, M. R. (2015). Classifying machinery condition using oil samples and binary logistic regression. *Mechanical Systems and Signal Processing*, 60, 316-325.
- [94]. Mukherjee, S., Sharma, N. (2012). Intrusion detection using naive Bayes classifier with feature reduction. *Procedia Technology*, 4, 119-128.
- [95]. Zhang, H. (2004). The optimality of naive Bayes. *AA*, 1(2), 3.
- [96]. Scikit-Learn, *Naive Bayes*, 21 Kasım 2019 tarihinde https://scikit-learn.org/stable/modules/naive_bayes.html#naive-bayes adresinden erişildi.

- [97]. Bustamante, C., Garrido, L., Soto, R. (2006, November). Comparing fuzzy naive bayes and gaussian naive bayes for decision making in robocup 3d. In *Mexican International Conference on Artificial Intelligence* (pp. 237-247). Springer, Berlin, Heidelberg.
- [98]. McCallum, A., Nigam, K. (1998, July). A comparison of event models for naive bayes text classification. In *AAAI-98 workshop on learning for text categorization* (Vol. 752, No. 1, pp. 41-48).
- [99]. Kibriya, A. M., Frank, E., Pfahringer, B., Holmes, G. (2004, December). Multinomial naive bayes for text categorization revisited. In *Australasian Joint Conference on Artificial Intelligence* (pp. 488-499). Springer, Berlin, Heidelberg.
- [100]. Rennie, J. D., Shih, L., Teevan, J., Karger, D. R. (2003). Tackling the poor assumptions of naive bayes text classifiers. In *Proceedings of the 20th international conference on machine learning (ICML-03)* (pp. 616-623).
- [101]. Scikit-Learn, *Multinomial Naive Bayes*, 21 Kasım 2019 tarihinde https://scikit-learn.org/stable/modules/naive_bayes.html#multinomial-naive-bayes adresinden erişildi.
- [102]. Çalışkan, S. K., Soğukpınar, İ. (2008). KxKNN: K-Means ve K en yakın komşu yöntemleri ile ağlarda nüfuz tespiti. *EMO Yayınları*, 120-24.
- [103]. Mejdoub, M., Amar, C. B. (2013). Classification improvement of local feature vectors over the KNN algorithm. *Multimedia Tools and Applications*, 64(1), 197-218.
- [104]. Keller, J. M., Gray, M. R., Givens, J. A. (1985). A fuzzy k-nearest neighbor algorithm. *IEEE transactions on systems, man, and cybernetics*, (4), 580-585.
- [105]. MathWorks, *KNN Algorithm*, 22 Kasım 2019 tarihinde <https://www.mathworks.com/matlabcentral/mlc-downloads/downloads/03faee64-e85e-4ea0-a2b4-e5964949e2d1/d99b9a4d-618c-45f0-86d1-388bdf852c1d/images/screenshot.gif> adresinden erişildi.
- [106]. Shannon, C. E. (1948). A mathematical theory of communication. *Bell system technical journal*, 27(3), 379-423.
- [107]. Ulgen E., K., *Makine Öğrenimi Bölüm-5 (Karar Ağaçları)*, 22 Kasım 2019 tarihinde <https://medium.com/@k.ulgen90/makine-ogrenimi-bolum-5-karar-agac-lari-c90bd7593010> adresinden erişildi.
- [108]. Ayhan, S., Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- [109]. Ulgen E., K., *Makine Öğrenimi Bölüm-4 (Destek Vektör Makineleri)*, 25 Kasım 2019 tarihinde <https://medium.com/@k.ulgen90/makine-ogrenimi-bolum-4-destek-vektor-makineleri-2f8010824054> adresinden erişildi.
- [110]. Morde V., *XGBoost Algorithm: Long May She Reign*, 25 Kasım 2019 tarihinde <https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d> adresinden erişildi.
- [111]. Chen, T., Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794). ACM.

- [112]. Zheng, H., Yuan, J., Chen, L. (2017). Short-term load forecasting using EMD-LSTM neural networks with a Xgboost algorithm for feature importance evaluation. *Energies*, 10(8), 1168.
- [113]. Choi, D. K. (2019). Data-Driven materials modeling with XGBoost algorithm and statistical inference analysis for prediction of fatigue strength of steels. *International Journal of Precision Engineering and Manufacturing*, 20(1), 129-138.
- [114]. Scikit Learn, *Multi Layer Perceptron*, 25 Kasım 2019 tarihinde https://scikit-learn.org/stable/modules/neural_networks_supervised.html#multi-layer-perceptron adresinden erişildi.
- [115]. Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222.
- [116]. Özdarıcı, A., Akar, Ö., Güngör, O., (2011, January). Rastgele orman sınıflandırma yöntemi yardımıyla tarım alanlarındaki ürün çeşitliliğinin sınıflandırılması, *TUFUAB 2011 VI. Teknik Sempozyumu*, Antalya.
- [117]. Koehrsen, W., *Random Forest Simple Explanation*, 27 Kasım 2019 tarihinde <https://medium.com/@williamkoehrsen/random-forest-simple-explanation-377895a60d2d> adresinden erişildi.
- [118]. Roy, R., *ML | Stochastic Gradient Descent (SGD)*, 28 Kasım 2019 tarihinde <https://www.geeksforgeeks.org/ml-stochastic-gradient-descent-sgd/> adresinden erişildi.
- [119]. Williams, C. K., Rasmussen, C. E. (2006). *Gaussian processes for machine learning* (Vol. 2, No. 3, p. 4). Cambridge, MA: MIT press.
- [120]. Liu, Y., Gu, Y., Nguyen, J. C., Li, H., Zhang, J., Gao, Y., Huang, Y. (2017). Symptom severity classification with gradient tree boosting. *Journal of biomedical informatics*, 75, S105-S111.
- [121]. Martínez-Rego, D., Fernández-Francos, D., Fontenla-Romero, O., Alonso-Betanzos, A. (2015). Stream change detection via passive-aggressive classification and Bernoulli CUSUM. *Information Sciences*, 305, 130-145.
- [122]. Matsushima, S., Shimizu, N., Yoshida, K., Ninomiya, T., Nakagawa, H. (2010, April). Exact passive-aggressive algorithm for multiclass classification using support class. In *Proceedings of the 2010 SIAM International Conference on Data Mining* (pp. 303-314). Society for Industrial and Applied Mathematics.

ÖZGEÇMİŞ

Adı ve Soyadı : Cevdet Tamer GÜVEN
Doğum Tarihi : 11.04.1993
E-mail : ctamerguven@gmail.com

Öğrenim Durumu :

Derece	Bölüm/Program	Üniversite	Yıl
Lisans	Bilgisayar Mühendisliği	İskenderun Teknik Üniversitesi	2012-2017
Yüksek Lisans	Bilgisayar Mühendisliği	Mersin Üniversitesi	2018-2020

ESERLER (Makaleler ve Bildiriler)

Makaleler

1. Güven, C.; Acı, M. (2019) Akıllı ev sistemleri için geliştirilen yapay sinir ağı tabanlı gezgin hizmet robotu. *European Journal Of Science And Technology*, Special Issue, 74-81.

Bildiriler

1. Güven, C.; Acı, M. (2019). A smart home system developed using artificial neural network on Raspberry Pi. Yakar, M.(Ed.), *Cilicia International symposium on engineering and technology Proceedings Book (CISSET 2019)* (pp. 723-727). Mersin: Mersin University. ISBN: 978-605-184-196-0

2. Güven, C.; Acı, M. (2019). Development of artificial intelligent based smart home system using Naive Bayes classifier. Yakar, M.(Ed.), *Cilicia International symposium on engineering and technology Proceedings Book (CISSET 2019)* (pp. 728-732). Mersin: Mersin University. ISBN: 978-605-184-196-0

3. Yergök, D.; Güven, C.; Acı, M., Artificial neural network model design for daily demand prediction in mass meal production. *International Conference on Advanced Technologies, Computer Engineering and Science Proceedings Book (ICATCES 2018)* (pp. 583-586). Karabük: Karabük University.