



T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü



BULUT BAĞLANTILI FOTOVOLTAİK İZLEME SİSTEMİ TASARIMI VE UYGULAMASI

Doktora Tezi

Ceyhun KAPUCU

Güneş Enerjisi Anabilim Dalı

İzmir
2019

T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

BULUT BAĞLANTILI FOTOVOLTAİK İZLEME SİSTEMİ TASARIMI VE UYGULAMASI

Ceyhun KAPUCU

Danışman: Dr. Öğr. Üyesi Mete ÇUBUKÇU

Güneş Enerjisi Anabilim Dalı

Enerji Teknolojisi Doktora Programı

İzmir
2019

Ceyhun KAPUCU tarafından Doktora tezi olarak sunulan “Bulut Bağlantılı Fotovoltaik İzleme Sistemi Tasarımı ve Uygulaması” başlıklı bu çalışma EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliği ile EÜ Fen Bilimleri Enstitüsü Eğitim ve Öğretim Yönergesinin ilgili hükümleri uyarınca tarafımızdan değerlendirilerek savunmaya değer bulunmuş ve 26.06.2019 tarihinde yapılan tez savunma sınavında aday oybirliği/oyçokluğu ile başarılı bulunmuştur.

Jüri Üyeleri:

İmza

Jüri Başkanı : Doç. Dr. Ali KEÇEBAŞ



Raportör Üye : Dr. Öğr. Üyesi Mete ÇUBUKÇU



Üye : Dr. Öğr. Üyesi Osman ÖZKARACA



Üye : Dr. Öğr. Üyesi Mustafa ENGİN



Üye : Dr. Öğr. Üyesi Dilşad ENGİN



EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

ETİK KURALLARA UYGUNLUK BEYANI

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Doktora Tezi olarak sunduğum “Bulut Bağlantılı Fotovoltaik İzleme Sistemi Tasarımı ve Uygulaması” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

26 / 06 / 2019



Ceyhun KAPUCU

ÖZET**BULUT BAĞLANTILI FOTOVOLTAİK İZLEME SİSTEMİ
TASARIMI VE UYGULAMASI**

KAPUCU, Ceyhun

Doktora Tezi, Güneş Enerjisi Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Mete ÇUBUKÇU

Haziran 2019, 108 sayfa

Fotovoltaik (FV) sistemler alanında artan araştırma ve geliştirme çalışmaları, FV sistemleri iyi bilinen yenilenebilir enerji kaynaklarından biri haline getirmiştir. Özellikle, yatırım destekleri ile küçük ve orta büyüklükteki sistemlerin kullanımı her geçen gün artmaktadır. Her ne kadar bu sistemlerin maliyetleri giderek azalsa da, ilk yatırım maliyetleri hala yüksektir. Bu nedenle FV sistemlerin yüksek verimle çalıştırılabilmesi, amortisman sürelerinin kısaltılması bakımından oldukça önemlidir.

Bu tezde, bir FV sistemden elde edilen elektriksel ve iklimsel verileri kullanarak hataları tespit edebilen bulut-bağlantılı bir izleme sistemi tasarımı yapılmış ve uygulanmıştır. Tez çalışması için Muğla ilinde bir konut üzerinde deneysel bir FV sistem kurulmuştur. Geliştirilen bir veri toplama sistemi tarafından deneysel sistemden elde edilen elektriksel ve iklimsel veriler anlık olarak bulut bilişim katmanına gönderilerek kaydedilmiş ve hata tespitinde kullanılmıştır. Hata tespiti için önerilen yöntem, topluluk öğrenmesi adı verilen bir makine öğrenmesi yönteminin, FV sistemlerdeki hataları sınıflandırmak amacıyla kullanılmasına dayanmaktadır. Topluluk öğrenmesi yöntemi, kavramsal olarak farklı öğrenme algoritmalarının tahminlerini birleştirerek, tek bir makine öğrenme algoritmasının genelleme yapma yeteneğinin ve tahmin doğruluğunun üzerine çıkabilmeyi amaçlar. Bu yöntem uzmanlar komitesi ya da kalabalıkların bilgeliği gibi kavramlarla da anılmaktadır. Geliştirilen hata tespiti yöntemi, bulut bilişim katmanında çalıştırılarak FV sistemin çalışma durumunu tahmin etmekte ve ardından yapılan tahmin, geliştirilen bir web servisi üzerinden cevap olarak sunulmaktadır.

Anahtar sözcükler: Fotovoltaik izleme, bulut bilişim, makine öğrenmesi, topluluk öğrenmesi, hata tespiti, çapraz doğrulama.

ABSTRACT**DESIGN AND IMPLEMENTATION OF CLOUD CONNECTED
PHOTOVOLTAIC MONITORING SYSTEM**

KAPUCU, Ceyhun

Ph.D. Thesis in Solar Energy

Supervisor: Asst. Prof. Dr. Mete ÇUBUKÇU

June 2019, 108 pages

The rising research and development studies in the domain of photovoltaic (PV) systems have made the PV systems one of the most well-known renewable energy sources. In particular, with invest supports, the use of small and medium-sized systems are increasing day by day. Although the costs of these systems are gradually decreasing, the initial investment costs are still high. Therefore, operating PV systems with high efficiency is very important in terms of shortening the depreciation periods.

In this thesis, a cloud-connected monitoring system that can detect faults by using electrical and climatic data obtained from a PV system has been designed and implemented. For the thesis study, an experimental PV system was installed on a residential building in Muğla. Electrical and climatic data obtained from the experimental system by a data acquisition system which is developed, have been recorded by sending instantly to the cloud-computing layer and then used for fault detection. The proposed method for fault detection is based on the use of a machine learning method called ensemble learning, to classify faults in PV systems. The ensemble learning method aims to exceed the generalizability and prediction accuracy over a single machine-learning algorithm by combining the predictions of conceptually different learning algorithms. This method is also aforementioned as the committee of experts or the wisdom of crowds. The developed fault detection method estimates the operation state of the PV system by running on the cloud computing layer and then the prediction is presented as a response through a web service developed.

Keywords: Photovoltaic monitoring, cloud computing, machine learning, ensemble learning, fault detection, cross validation.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL ONAY SAYFASI	iii
ETİK KURALLARA UYGUNLUK BEYANI.....	v
ÖZET	vii
ABSTRACT	ix
İÇİNDEKİLER	xi
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ.....	xvii
SİMGELER VE KISALTMALAR DİZİNİ	xix
1. GİRİŞ.....	1
2. ÖNCEKİ ÇALIŞMALAR	3
2.1. FV İzleme Sistemleri	3
2.2. FV Sistemlerde Hata Tespiti.....	8
3. FV GÜÇ SİSTEMLERİ.....	22
4. MAKİNE ÖĞRENMESİ.....	33
4.1. Terminoloji	34
4.1.1. Veri seti.....	34
4.1.2. Hedef fonksiyon.....	35
4.1.3. Hipotez.....	35
4.1.4. Sınıflandırıcı	35
4.1.5. Öğrenme algoritması	35
4.1.6. Model.....	36
5. TOPLULUK ÖĞRENMESİ.....	37
5.1. Topluluk Öğrenmesi Yöntemleri.....	37
5.1.1. Algoritma çeşitliliğine göre topluluk öğrenmesi yöntemleri.....	37
5.1.2. Oluşturma şekline göre topluluk öğrenmesi yöntemleri.....	38
6. GEREÇ VE YÖNTEM.....	43
6.1. Deneysel Sistem.....	45
6.2. Bulut Bağlantılı İzleme Sistemi.....	47
6.2.1. İstemci tarafı	47

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
6.2.2. Sunucu tarafı	58
6.3. Hata Tespit Sistemi	62
6.3.1. Hata tespit sisteminin oluşturulması	63
6.3.2. Özellik seçimi	64
6.3.3. Öğrenme algoritmalarının optimizasyonu	70
6.3.4. Topluluk modelinin oluşturulması	79
6.3.5. Topluluk modelinin optimizasyonu	86
6.4. Hata Tespit Sisteminin Bulut Katmanında Çalıştırılması	87
7. DEĞERLENDİRME VE SONUÇLAR.....	94
KAYNAKLAR DİZİNİ	101
TEŞEKKÜR.....	107
ÖZGEÇMİŞ	108

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1. Tahmin edilen ve ölçülen enerjideki fark grafiği (Riley and Johnson, 2012).	10
2.2. I/V eğrisindeki değişimler (Bonsignore et al., 2014).	11
2.3. Etiketlenmiş verilerin kümelenmesi (Zhao et al., 2015).	13
2.4. Gölgeleşmiş hücre sayısına göre MAE değerleri (a) Akım, (b) Gerilim (Mekki et al., 2016).	16
2.5. Hata tespiti ve sınıflandırma yöntemi (Chine et al., 2016).	17
2.6. Rastgele orman modeli hata tespit yöntemi (Chen et al., 2018).	19
2.7. Hata senaryoları benzetim şeması (Chen et al., 2018).	20
3.1. Dünya birincil enerji kaynaklarının tüketimi (Vaclav Smil, 2017).	22
3.2. Yenilenebilir enerji kaynaklarının dünya çapında elektrik üretimindeki tahmini payı (<i>Renewables 2018 Global Status Report</i> , 2018).	23
3.3. Dünya üzerinde elektriğe erişimi bulunan insan sayısı (<i>World Bank World Development Indicators</i> , 2017).	23
3.4. FV hücre yapısı (Sampaio and González, 2017).	24
3.5. Tek diyot modelinin elektriksel eşdeğer devresi.	25
3.6. FV panele ait tipik I-V ve P-V eğrileri.	26
3.7. I-V ve P-V eğrilerinin ışınımına göre değişimi.	28
3.8. I-V ve P-V eğrilerinin hücre sıcaklığına göre değişimi.	28
3.9. Matlab ile tek panelde gölgeleşme benzetimi.	30
3.10. FV dizideki tek panelde gölgeleşme.	30
3.11. FV enerjiyle çalışan su pompalama sistemi (Gopal et al., 2013).	31
3.12. Yıllara göre FV panel fiyatları ve toplam kurulu güç (Lafond et al., 2018).	32
3.13. FV hücre teknolojileri araştırmalarında yıllara göre elde edilen verimler (NREL, 2019).	32
4.1. Boston veri setinden örnekler.	34
5.1. Rastgele orman modelinin yapısı.	40
6.1. Bulut bağlantılı FV izleme sistemi şematik gösterimi.	43
6.2. FV izleme sistemi hata tespit adımları.	44
6.3. Deneysel güç sistemi.	45
6.4. PVGIS'e göre en uygun eğim ve azimut açıları.	46

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
6.5. FV izleme sistemi istemci-sunucu yapısı.....	47
6.6. Arduino uyumlu Mega+WiFi geliştirme kartı.	48
6.7. Apogee, PYR-S model piranometre.....	50
6.8. Maxim, DS18B20 sıcaklık algılayıcısı.	51
6.9. Panel arkasındaki sıcaklık algılayıcıları.....	52
6.10. Sıcaklık algılayıcısı bağlantı şeması.	53
6.11. Texas Instruments, INA226 akım, gerilim algılayıcısı.	53
6.12. INA226 algılayıcısı bağlantı şeması.	54
6.13. Adafruit, DHT22 sıcaklık ve bağıl nem algılayıcısı.	54
6.14. Micro SDHC bellek kartı adaptörü.	55
6.15. Esp birimi ve sunucu tarafındaki haberleşme.....	56
6.16. Web tarayıcısından yapılmış http isteği.	57
6.17. Komut satırından curl aracı ile yapılmış http isteği	58
6.18. Veri yönetim web servisinin (VYWS) çalışma şekli.....	59
6.19. Veri biliminde Python-R-Matlab kullanımı (“Data science trends,” 2019)..	61
6.20. Makine öğrenmesinde Python-R-Matlab kullanımı (“Machine learning trends,” 2019).....	61
6.21. Öğrenme modellerindeki uyumlanma çeşitleri örneği.....	65
6.22. Bir paneldeki gölgelenme senaryosu.	68
6.23. Bir paneldeki kısa devre senaryosu.....	69
6.24. Hata senaryoları gerçekleştirme şeması (a) Normal çalışma, (b) Tek panelin gölgelenmesi, (c) İki panelin gölgelenmesi, (d) Tek panelin kısa devre olması....	69
6.25. Eğitim/test veri ayrımı örneği.	71
6.26. 10 katlı çapraz doğrulama örneği.....	72
6.27. Karışıklık matrisi örneği.	76
6.28. Normalleştirilmiş karışıklık matrisleri (a) GB, (b) QDA.....	78
6.29. Normalleştirilmiş karışıklık matrisleri (a) <i>ETgini</i> , (b) <i>ETent</i>	78
6.30. Normalleştirilmiş karışıklık matrisleri (a) <i>RFgini</i> , (b) <i>RFent</i>	79
6.31. Normalleştirilmiş karışıklık matrisleri (a) DT, (b) LR.	79
6.32. 1. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.	83

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
6.33. 2. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.....	83
6.34. 3. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.....	84
6.35. 4. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.....	84
6.36. 5. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.....	84
6.37. En başarısız topluluk aday modelin normalleştirilmiş karışıklık matrisi.	85
6.38. Son topluluk modelinin normalleştirilmiş karışıklık matrisi.	87
6.39. Sayısal dosya olarak kaydedilen topluluk modeli içeriği.	88
6.40. Bir test örneği için yapılmış normal çalışma tahmini.	90
6.41. Bir test örneği için yapılmış tek panelin gölgelenme hatası tahmini.	90
6.42. Bir test örneği için yapılmış iki panelin gölgelenme hatası tahmini.	90
6.43. Bir test örneği için yapılmış tek panelin kısa-devre hatası tahmini.	91
6.44. Test veri setindeki bir örnek için curl aracı ile yapılmış tahmin isteği.	92
6.45. Hata tahmini için kullanıcılara gönderilen e-posta bildirimi.	93
7.1. Kullanılan modellere ait tahmin doğrulukları ortalamaları.	97

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
6.1. Topray Tps105S mono-kristal FV panel teknik özellikleri.	46
6.2. Mega+WiFi kartı çalışma şekilleri.	48
6.3. DS18B20 sıcaklık algılayıcısı çözünürlük seçenekleri.....	53
6.4. Topluluk öğrenmesi modelinde kullanılan kütüphaneler.	63
6.5. Ki-kare testiyle belirlenmiş özellik skorları.	66
6.6. Hata tiplerinin sınıflandırılması.	67
6.7. Algoritmalarda şebeke-araması yapılan parametreler.	73
6.8. Optimize edilmiş algoritmaların ortalama tahmin kaliteleri.....	74
6.9. Algoritmaların tahmin kalitesinde performans ölçütleri.....	74
6.10. Algoritmaların hata tipleri için tahmin doğrulukları.	77
6.11. En başarılı aday topluluk modellerinin ortalama tahmin kaliteleri.	82
6.12. En başarısız aday topluluk modellerinin ortalama tahmin kaliteleri.	85
6.13. Topluluk modelinde oylama tipi ve ağırlıklar parametreleri için seçenekler.	86
6.14. Son topluluk modelinin ortalama tahmin kalitesi.	86

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler Açıklama

AC	Alternatif Akım
API	Application Programming Interface – Uygulama Programlama Arayüzü
CART	Classification and Regression Trees – Sınıflandırma ve Regresyon Ağaçları
DAQ	Data Acquisition – Veri Toplama
DC	Doğru Akım
DT	Decision Tree – Karar Ağacı
ET	Extra Trees – Ekstra Ağaçlar
GB	Gradient Boosting – Gradyan Artırma
GPS	Global Positioning System – Küresel Konumlama Sistemi
HTML	Hypertext Markup Language – Hiper Metin İşaretleme Dili
I_{mp}	Maksimum Güçteki Akım (A)
I_{sc}	Kısa Devre Akımı (A)
IEC	International Electrotechnical Commission
IoT	Internet of Things – Nesnelerin İnterneti
IP	Internet Protocol – İnternet Protokolü
LR	Logistic Regression – Lojistik Regresyon

SİMGELER VE KISALTMALAR DİZİNİ (devam)**Simgeler Açıklama**

MPP	Maximum Power Point – Maksimum Güç Noktası
MPPT	Maximum Power Point Tracking – Maksimum Güç Noktası Takibi
PC	Personal Computer – Kişisel Bilgisayar
PHP	Hypertext Preprocessor – Hiper Metin Ön İşlemcisi
PLC	Power Line Communication – Güç Hattı Haberleşmesi
QDA	Quadratic Discriminant Analysis – İkinci Dereceden Ayrımcı Analiz
RF	Random Forest – Rastgele Orman
STC	Standard Test Conditions – Standart Test Koşulları
TCP	Transfer Control Protocol – Transfer Kontrol Protokolü
V_{mp}	Maksimum Güçteki Gerilim (V)
V_{oc}	Açık Devre Gerilimi (V)

1. GİRİŞ

Günümüzde temel enerji kaynağı olarak kullanılan fosil yakıtlara ait rezervler giderek azalmaktadır. Bununla birlikte tüm dünyada enerji talebinin sürekli artması ve fosil yakıtların çevreye olan zararı düşünüldüğünde, fosil yakıtlara alternatif enerji kaynaklarına yönelim giderek önem kazanmaktadır. Yenilenebilir enerji, sınırsız sayılabilecek kaynakları, çevre dostu olmaları ve gelişen teknolojiyle birlikte artan verimleri sayesinde fosil yakıtlara en iyi alternatif enerji kaynaklarıdır.

Yenilenebilir enerji kaynakları arasında en çok kullanılanlardan biri güneş enerjisidir. Güneş enerjisinden elektrik enerjisi elde etme yöntemlerinin en bilineni FV panellerdir. FV panellerden oluşan güç sistemlerinin izlenmesi, bu sistemlerin verimli çalışması açısından önemli bir işlemdir. Verimliliğin takip edilebilmesi için izlenmesi gereken en önemli değişken gerçekleştirme oranıdır. FV sistemler için ortalama gerçekleştirme oranı değeri geçtiğimiz 20 yıl boyunca giderek artmış ve %65'ten %85'e yükselmiştir. Bu artışı mümkün kılan, FV sistemlerin izlenmesi ve toplanan verilerin analiz edilmesi olmuştur. FV sistemlerde istenmeyen verim düşüklüğünün en önemli nedenleri olarak, çıkış gücünü düşüren yüksek panel sıcaklığı, panel yüzeyine gelen güneş ışığının kir-toz ve benzeri etmenler tarafından engellenmesi, paneller-panel dizileri arasındaki uyumsuzluk, kablolama kayıpları ve AC çıkış veren sistemlerde kullanılan eviricilerin kayıpları gösterilebilir (Woyte et al., 2013). Bu nedenle etkili bir izleme sistemi, FV sistemdeki olası hataları tanımlayarak sistemin çalışma performansını belirleyebilmelidir. Günümüz izleme sistemleri genellikle evirici tarafından FV dizi seviyesinde yapılmaktadır. Myrzik ve Calais'e göre dizi seviyesinde evirici kullanımı merkezi evirici ya da panele bütünleşik evirici kullanımından daha yaygındır (Myrzik and Calais, 2003). Araştırmacılar bunun sebebi olarak merkezi eviricilerde çok sayıda panel için maksimum güç noktası takibinin (Maximum Power Point Tracking – MPPT) zor olması ve farklı kurulumlar için ölçeklenebilirliğin düşük olmasını gösterirken, panele bütünleşik eviricilerin bir seri üretim olmadıkça yüksek kalan maliyetlerini göstermişlerdir. Orta ve büyük ölçekli bir FV sistemde çok fazla sayıda panel olduğundan, bir hata durumunda hatalı panelleri içeren diziyi doğru ve hızlı bir şekilde tespit etmek önemli hale gelmektedir (Guerriero et al., 2013). Uluslararası IEC 61724 standardına göre bir FV güç sisteminin izlenmesi sırasında anlık olarak

ölçülmesi gereken veriler, ölçüm algılayıcılarının hassasiyet oranları, ölçüm zaman aralıkları, ölçüm verilerinin kaydedilme zaman aralıkları ve kaydedilme formatları belirtilmiştir (IEC 61724, 1998). Sistemin performansını belirleyen bu verilerin ölçme, iletim ve değerlendirilmesi için bugüne kadar pek çok çalışma yapılmıştır. Çalışmaların çoğunda, IEC 61724 standardında belirtilen, ölçülmesi gereken veri tipi sayısından daha az miktarda veri tipi ölçülerek izleme ve hata tespiti aşamalarında kullanılmıştır.

Bu tez çalışmasının amacı, FV izleme sistemlerini bütünlük bir hata tespit yöntemi ile donatırken, yapay zekâ temelli geleneksel hata tespit yöntemlerinin genelleme yapma yeteneğinin ve tahmin doğruluğunun üzerine çıkabilecek özgün bir hata tespit sisteminin geliştirilmesidir.

2. ÖNCEKİ ÇALIŞMALAR

FV izleme sistemleri gelişen teknoloji ile üzerinde çok çalışılan bir alan olmuştur. Literatür araştırması, FV izleme sistemleri ve FV sistemlerde hata tespiti çalışmaları şeklinde iki ayrı başlık altında ele alınmış ve incelenen çalışmalar paylaşılmıştır.

2.1. FV İzleme Sistemleri

Ryu ve arkadaşları çalışmalarında, FV izleme sistemleri için verilerin saklanabileceği bir bulut bilişim depolama servisi yapısı ile bu buluttan verileri çekebilen bir web uygulaması tasarımı ortaya koymuşlardır. Çalışmada FV sistemden elektriksel ve iklimsel verilerinin toplanması için herhangi bir yöntem önerilmemiştir (Ryu et al., 2012). Bu çalışmada ortaya konulan yapı, herhangi bir FV izleme sistemi için veri toplama adımlarını hâlihazırda gerçekleştirmiş, toplanan verileri saklamak ve uzaktan izlemek isteyen kullanıcılar tarafından kullanılabilir. Fakat kullanıcılar depolama servisinin verileri saklamak için kullandığı veri tabanı veri yapılarına birebir uymak zorundadırlar. Ayrıca hem bulut bilişim servisini bir web uygulama sunucusunda barındırmak ve bu sunucunun çalışmada kullanılan veri tabanı yönetim sistemine erişimini sağlamak sorumluluğu da kullanıcılarda olacaktır. Çalışmanın uzaktan izleme ayağı ise mobil cihazların ekran çözünürlükleri için özel olarak uyarlanmış web sayfalarından oluşan bir web uygulamasıdır.

Düştegör ve arkadaşı tarafından yapılan bir çalışmada, fosil enerji kaynakları açısından oldukça zengin olan Körfez ülkelerinin sahip olduğu çok özel iklim koşullarında çalışan FV sistemlerin karşılaştığı performans düşürücü hava sıcaklığı, kum fırtınalarından kaynaklı tozlanma ve nem gibi çevresel koşulların etkilerinin analiz edilebilmesi amacıyla bir izleme sistemi önerilmiştir. Bu izleme sisteminde, ZigBee¹ tabanlı algılayıcı düğümlerinden elde edilen panel ve ortam sıcaklığı, nem, ışınım, tozlanma miktarı gibi veriler açık kaynak kodlu Processing² dili ile

¹ Düşük güç tüketimli kablosuz standardı (<https://www.zigbee.org/> erişim tarihi 21 Şubat 2019).

² <https://processing.org/> erişim tarihi 20 Şubat 2019.

geliştirilmiş bir PC tabanlı yazılım aracılığıyla izlenmiştir (Düştegör ve Felemban, 2013).

Papageorgas ve arkadaşlarının bir çalışmasında, FV panellere bütünleşik mikro-denetleyici kontrollü veri toplama kartları ile elde edilen veriler, kablolu seri haberleşme veri yolu üzerinden toplanarak bir grup panelin bir FV panel kümesi oluşturması sağlanmakta ve bu kümeler ise ZigBee modülleri üzerinden kablosuz olarak bir FV sistemler yöneticisinde toplanmaktadır. FV sistemler yöneticisi Arduino temelli olup, topladığı verileri Ethernet kablosu üzerinden açık kaynak kodlu web yayınlama servisi olan Cosm¹ üzerine yüklemektedir. Sistem verileri Cosm servisinin kendi arabiriminden izlenebilmektedir (Papageorgas et al., 2013).

Kun ve arkadaşlarının bir çalışmasında, FV sistemlerde kullanılan eviricilerin yerinde izlenebilmesi için STM32F103ZET6 mikro-denetleyicisi ile kontrol eden evirici detektörü adı verilen bir cihaz geliştirilmiştir. Geliştirilen bu cihaz eviriciye RS232 üzerinden bağlanarak evirici verilerini anlık olarak okumaktadır. Okunan bu veriler bir LCD üzerinden gösterilmekte ve AT45DB161 belleğinde saklanmaktadır. Ayrıca bir Android² uygulaması geliştirilmiş ve bu uygulamayı çalıştıran bir akıllı telefon, evirici detektörü ile haberleşecek yakınlıkta olduğunda Bluetooth kablosuz iletişim kanalı üzerinden detektör ile eşleşerek verileri akıllı telefona indirebilmektedir. Akıllı telefon ile detektör arasındaki iletişim mesafesi açık alanda en fazla 100 metre ile sınırlıdır (Kun et al., 2013).

Tina ve arkadaşı tarafından yapılan bir çalışmada ise DC kompresörlü bir soğutucunun, yüzeylerine bütünleşik FV panellerden elde ettiği enerji yardımıyla çalıştırılması ve performansının izlenebilmesi amacıyla şebekeden bağımsız FV sistemlerde de kullanılacak bir izleme sistemi geliştirilmiştir. Geliştirilen sistem farklı algılayıcılar ve veri toplama (Data Acquisition – DAQ) kartı kullanmaktadır. Soğutucu içi sıcaklık değerlerinin de eklendiği performans verileri standart

¹ Bulut bilişim platformunun eski adı – (<https://xively.com/> erişim tarihi 27 Temmuz 2017).

² <https://www.android.com/> erişim tarihi 27 Temmuz 2017.

MODBUS¹ TCP/IP protokolü üzerinden Ethernet aracılığıyla bir sunucuda çalışan veri tabanına yüklenmekte ve bu veri tabanını kullanan bir web uygulaması üzerinden kullanıcılara gösterilmektedir (Tina and Grasso, 2014).

Tejwani ve arkadaşlarının bir çalışmasında, FV sistemlerin kırsal alan uygulamalarında kullanılacak bazı izleme sistemleri karşılaştırılmış ve veri aktarım yöntemi olarak GSM şebekesi ses kanalının kullanıldığı ve verilerin analog sinyallere dönüştürülerek aktarıldığı yeni bir izleme sistemi önerilmiştir. Veri aktarımında %1'den daha az kayıp ile sonuçlanan bu izleme sistemi, GSM şebekeleri kırsal alanlarda da erişilebilir olduğu için kolaylıkla kullanılacak bir izleme sistemi olarak önerilmiştir (Tejwani et al., 2014).

Belghith ve arkadaşının bir çalışmasında, FV sistemden elde edilen ortam sıcaklığı, ışınım, batarya durumu, gerilim, akım ve güç verileri PIC16F877 temelli bir elektronik devre tarafından RS232² protokolü üzerinden Wavecom GSM modemine gönderilmektedir. GSM modemi kendisine gönderilen verilerin merkezi izleme sistemine iletimi için kısa mesaj servisi (Short Message Service - SMS) kullanmaktadır. Merkezi izleme sisteminde alıcı olarak aynı türden bir GSM modemi kullanılmakta ve bu modeme SMS olarak gelen veriler RS232 protokolü üzerinden LabVIEW³ arabiriminde analiz edilmekte ve gösterilmektedir (Belghith and Sbita, 2014). GSM şebekelerinde meydana gelen tıkanıklıklardan dolayı bazen SMS iletimi gecikebilmektedir. Bu gecikme birkaç dakikadan birkaç saate çıkabilmekte ya da tamamen başarısız olabilmektedir.

Shariff ve arkadaşları çalışmalarında, kablolu iletimin getirdiği bazı sınırlamalardan dolayı ZigBee tabanlı kablosuz iletimi tercih etmişlerdir. Geliştirdikleri 8 bitlik PIC18F553 mikro-denetleyicisinin kontrolündeki kart ve bağlı algılayıcılar ile sıcaklık, ışınım, FV sistem çıkış gücü, evirici çıkış gücü gibi

¹ Modicon firması tarafından 1979'da geliştirilen mesajlaşma yapısı (<http://www.modbus.org/faq.php> erişim tarihi 20 Şubat 2019).

² Seri iletişim veri yolu standardı (<https://en.wikipedia.org/wiki/RS-232> erişim tarihi 20 Şubat 2019).

³ <https://www.ni.com/en-us/shop/labview.html> erişim tarihi 20 Şubat 2019.

veriler izlenmiş, verilerin uzaktan izlenmesi için ayrıca web tabanlı bir izleme sistemi geliştirilmiş ve 1,25kWp şebeke bağlantılı bir FV sisteme uygulanmıştır. Geliştirilen sistemde toplanan veriler merkez bilgisayardaki bir Excel dosyasına kaydedilmiş ve yine aynı bilgisayarda bulunan bir web sunucu üzerinden PHP programlama dili ile geliştirilmiş bir web sayfası üzerinden internet ortamında yayınlanarak uzaktan izleme sağlanmıştır (Shariff et al., 2015). Bu çalışmada verilerin depolanması ve internet ortamında yayınlanması için ayarlanmış bir PC'nin sürekli çalışır vaziyette tutulması gerekmektedir.

Karoly ve arkadaşlarının bir çalışmasında, bir FV sisteme ait elektriksel ve elektriksel olmayan verilerin ölçümü ve işlenmesi için üzerinde mikro-denetleyici bulunduran Arduino geliştirme kartı ve bu karta uyumlu algılayıcılar kullanılmıştır. Algılayıcılardan ölçülen veriler, Arduino geliştirme kartına takılabilen ve bağlanacağı yerel alan ağında yerel bir IP adresi alması için programlanmış bir Ethernet modülü üzerinden ağ yönlendiriciye bağlanarak yerel ağda görüntülenebilecek basit bir hiper metin işaretleme dili (Hypertext Markup Language – HTML) dosyası yaratılmış ve ölçülen verilerin izlenebilmesi sağlanmıştır (Karoly and Dumitru, 2015). Bu çalışmada oluşturulan izleme sistemi oldukça basit bir web tabanlı izleme sistemidir, ölçülen verilerin herhangi bir şekilde saklanması söz konusu değildir ve sadece yerel alan ağı içerisinde görünür olacağından herkese açık internet üzerinden izlenememektedir.

Hu ve arkadaşlarının çalışmalarında, farklı noktalarda bulunan FV sistemlerinden özel tasarlanmış kartlar ile elde edilen anlık akım, gerilim, güç ve güneş ışınımı verileri birleştirilerek ZigBee ağı üzerinde bir izleme merkezine gönderilmekte ve bu merkezde özel olarak kurulmuş bir Hadoop¹ bulut ortamında saklanmaktadır. Çalışmada büyük miktardaki veri saklamak için kullanılacak bu Hadoop kümesini oluşturmak için 5 ayrı sunucu kullanılmıştır (Hu et al., 2015). İlgili çalışmada izleme için tasarlanmış özel bir uygulamadan bahsedilmemiştir.

¹ Büyük verilerin, sunucu kümeleri üzerinde saklanıp işlenmesini sağlayan açık kaynak kodlu yazılım çatısı (<https://hadoop.apache.org/>).

Visconti ve arkadaşı tarafından yapılan bir çalışmada, FV sistemlerini arıza tespiti ve hırsızlık engelleme için izleyebilen ve en uygun performans için güneşi takip edebilecek şekilde kontrol edebilen bir elektronik sistem tasarlanmıştır. PIC16F887A tabanlı olarak tasarlanan bir elektronik devre ile okunan gerilim, akım, sıcaklık ve güneş ışınımı verileri RS485¹ arabirimi üzerinden bir PC'ye aktarılmakta ve saklanmaktadır. Ayrıca FV panellerin eğim ve yön açılarını optimize etmek için bir küresel konumlama sistemi (Global Positioning System – GPS konum algılayıcısından aldığı bilgileri kullanarak panellerin güneşi takip edebilmesini sağlayan iki ayrı motoru süren PIC16F876 tabanlı bir elektronik devre de ayrıca tasarlanmıştır (Visconti and Cavallera, 2015).

Li ve arkadaşları, bir çalışmalarında açık kaynak kodlu platformların kullanıldığı bir izleme sistemi önermişlerdir. Çalışmada FV sistemden elde edilen akım, gerilim değeriyle birlikte güneş ışınımı ve sıcaklık bilgileri toplanmış ve bu bilgiler ZigBee ağı aracılığıyla toplanmış ve Raspberry Pi2 geliştirme kartının yönettiği bir katman üzerinde hata tespiti de yapıldıktan sonra açık kaynak kodlu IoT platformu Ubidots'a² gönderilmiştir. Toplanan veriler Ubidots servisinin kendi arabiriminden izlenebilmektedir (Li et al., 2018).

Literatürde daha az parametrenin ölçüldüğü FV panel seviyesinde yapılan izleme çalışmaları da mevcuttur. Jonke ve arkadaşları, bir çalışmalarında düşük maliyetli, panel tabanlı bir FV izleme sistemi önermişlerdir. Önerilen sistemde her panel üzerinde bütünleşik şekilde çalışan ve panelin I/V parametrelerini merkezi birime gönderen, gerektiğinde panelin, dizi ile bağlantısını sağlayan veya koparan, merkezi birim ile enerji hattı üzerinden haberleşme (Power Line Communication - PLC) ile veri iletimi ve kontrolünün yapıldığı bir sistem önerilmiştir. Yapılan çalışmada sistemi kontrol etmek için LabVIEW ile geliştirilmiş bir arabirim aynı zamanda sistemden gelen verileri de görüntüleyebilmektedir (Jonke et al., 2013).

¹ Seri iletişim veri yolu standardı (<https://en.wikipedia.org/wiki/RS-485> erişim tarihi 20 Şubat 2019).

² <https://ubidots.com/> erişim tarihi 20 Şubat 2019.

Prieto ve arkadaşlarının bir çalışmalarında panel seviyesinde çalışan ve gücünü yine aynı panellerden alan ZigBee tabanlı algılayıcı düğümlerinden elde edilen sıcaklık, ışınım, akım ve gerilim verileri, yine ZigBee tabanlı merkez düğüme gönderilmiş ve oradan da PC tabanlı bir izleme merkezinde toplanmıştır (Prieto et al., 2014).

FV sistemlerde hata tespiti ile ilgili çalışmalar bir sonraki bölümde ele alınmıştır.

2.2. FV Sistemlerde Hata Tespiti

FV sistemler için hata tespiti yöntemleri genel olarak, görsel, termal ve elektriksel yöntemler şeklinde gruplandırılabilir (Ando et al., 2015). Elektriksel yöntemi temel alan yaklaşımlar ise sırayla; güneş ışınımı, sıcaklık gibi iklimsel verilere ihtiyaç duyulmayan yaklaşımlar, FV güç sisteminin akım, gerilim karakteristiğinin analiz edildiği yaklaşımlar, en yüksek güç noktasının takip edildiği yaklaşımlar, yapay zekâ teknikleri kullanan yaklaşımlar ve bunların dışında kalan diğer yaklaşımlar olarak ele alınabilir (Chine et al., 2016). Son yıllarda, FV sistemlerde hata tespitinde yapay zekâ tekniklerinin kullanımı giderek artmaktadır.

Ducange ve arkadaşları çalışmalarında, FV güç sistemlerinde bulunan eviricilerden kolaylıkla elde edilebilen akım ve gerilim çıkış değerlerinin analizine dayanan Takagi-Sugeno-Khan bulanık kural tabanlı sistem (Takagi-Sugeno-Khan Fuzzy Rule-Based System – TSK-FRBS) kullanan bir hata tespit sistemi önermişlerdir (Ducange et al., 2011). Sistem hata tespit ve teşhis olmak üzere iki ayrı modülden oluşmuştur. Önerilen sistemde öncelikle anlık ölçülen güneş ışınımı ve panel sıcaklığı giriş verileri kullanılarak FV sistemdeki her bir dizinin üretmesi gereken DC güç değeri tahmin edilir. Ardından hata tespit modülü tarafından, tahmin edilen güçler ile gerçek güçler ($P_{MPPT} = [P_1, \dots, P_K]$) karşılaştırılarak, ayırt edilebilir bir fark durumunda hata varlığını belirten alarm sinyalleri üretilir ($A = [A_1, \dots, A_K]$). Bu alarm sinyalleri hata teşhis yöntemi tarafından analiz edilerek hata tipleri belirlenmeye çalışılır. Tahmin işlemi için TSK-FRBS kullanılmıştır. TSK-FRBS bir kural tabanlı, giriş ve çıkış değerlerinin dilsel değişkenlerle (az, orta, çok, normal vb.) tanımlanmasında kullanılan terimlerin açıklamasının tutulduğu bir veri tabanı ve bir çıkarım motorundan oluşmaktadır. Öncelikle veri uzayı, her biri

FV sistemin belirli bir davranışını betimleyen bulanık kümelere ayrılmaktadır. Böylelikle modeldeki her bir küme bir kurala karşılık gelmektedir. Hata tespit sistemi içerisinde üretilecek gücün tahmin edilebilmesi için sistemi eğitmek amacıyla hata oluşmamış ve sağlıklı çalışan bir FV sisteme ait giriş ve çıkış verileri kullanılmıştır. FV sistemin eskimesi sebebiyle oluşacak güç düşüşlerini de hesaba katmak için, ilerleyen süreçte aynı FV sisteminden elde edilecek yeni verilerle modelin tekrar eğitilmesi önerilmiştir. Çalışmada gerçek bir FV sistem yerine bir benzetim modeli kullanılmış, normal ve hatalı çalışma şartları bu model üzerinden oluşturulmuştur. Işınım verileri için ise bir meteoroloji istasyonundan elde edilmiş veriler kullanılmıştır. Benzetim sonucu elde edilen veriler ile tahmin edilen veriler arasındaki hatayı ölçmek için kullanılan ortalama mutlak yüzdelik hata (Mean Absolute Percentage Error – MAPE) aşağıdaki eşitlik ile elde edilmiştir.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y_i^*}{y_i} \right| * 100 \quad (2.1)$$

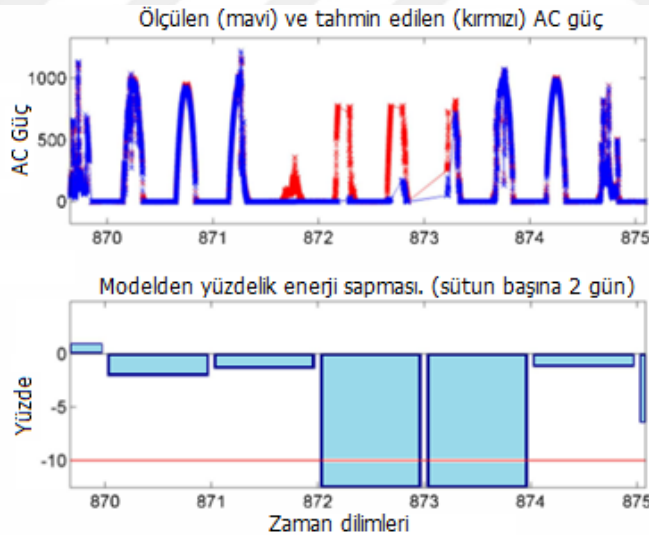
Eşitlik 2.1’de y_i ölçülen güç değerlerini, y_i^* tahmin edilen güç değerlerini, N ise örnek sayısını göstermektedir. Karşılaştırma sonucu sağlıklı çalışan bir FV sistemde MAPE değeri %3’ü geçmemiştir. Bu nedenle hata olduğunu belirten alarm sinyalleri için eşik değeri %5 olarak seçilmiştir. Çalışma sonucunda önerilen sistemin %90 üzerinde doğru tespit ettiği belirtilmiştir.

Riley ve Johnson’ın bir çalışmasında, FV sistemlerin sağlıklı çalıştığını kontrol eden ve hata durumunda uyarabilen, parçacık sürüsü eniyilemesi ile eğitilmiş Yapay Sinir Ağları (YSA) temelli bir yöntem önermişlerdir (Riley and Johnson, 2012). Önerilen yöntemde, iki FV güç santralinden kurulumlarından itibaren toplanan güneş ışınımı, rüzgâr hızı, hava sıcaklığı ve AC güç çıkışı verileri kullanılmıştır. Çalışmada performans değerlendirmesi AC güç çıkışı için yapılmakla beraber istenirse farklı çıktılar için de yöntemin kullanılabilceği belirtilmiştir. Kurulumdan itibaren veri toplandığı için ilk zamanlara ait seçilen 6 aylık veri setinin, FV sistem için en düşük kirlenme, eskime ve hata barındırdığı kabul edilerek, sağlıklı çalışma şartlarına ait veriler olduğu kabul edilmiştir. Çalışmada amaç toplanan bu veriler kullanılarak eğitilmiş YSA temelli bir modelin, tahmin ettiği AC güç çıkışı ile sistem çalışır durumdayken ölçülecek AC güç

çıkışını karşılaştırmak ve ikisi arasındaki farkın belirli bir eşik değerini aşmış olmadığını kontrol etmektir. Bunun için öncelikle toplanan verinin 2 aylık kısmı ile YSA modeli eğitilmiştir. Tahmin edilen ve ölçülen AC güç çıkışı farkları aşağıdaki eşitlik ile elde edilmiştir.

$$\% \text{ Energy Loss} = 100 * \left(\frac{\sum_n(P_{meas})}{\sum_n(P_{model})} - 1 \right) \quad (2.2)$$

Eşitlikte n dikkate alınan zaman aralığındaki ölçüm sayısı, P_{meas} ölçülen AC güç, P_{model} tahmin edilen AC güç değerleridir. Burada zaman aralığı olarak 2 günlük dönemler seçilmiş ve bu karşılaştırma işlemi her dönem için ayrı ayrı yapılmıştır. Örneğin gerçek sistemden 2 günlük güneş ışınımı, rüzgâr hızı, hava sıcaklığı ve AC güç çıkışı ölçümü toplanmış ve bu değerlerden güneş ışınımı, rüzgâr hızı ve hava sıcaklığı YSA modelinin giriş parametreleri olacak şekilde model çalıştırılarak tahmini AC güç çıkışları elde edilmiştir. Ardından tahmin edilen ve ölçülen bu AC güç çıkışı değerleri Eşitlik 2.2 kullanılarak karşılaştırılmıştır. Şekil 2.1’te bu karşılaştırma grafik olarak gösterilmiştir.



Şekil 2.1. Tahmin edilen ve ölçülen enerjideki fark grafiği (Riley and Johnson, 2012).


Hata yakalama için alarm seviyesini belirleyen eşik değeri bu örnekte %5 seçilmiş olup, takip edilen FV sistemin büyüklüğüne göre değiştirilebilir. Çalışmalarında araştırmacılar daha büyük sistemler için daha küçük eşik değerlerinin uygun olacağını belirtmişlerdir. Ayrıca eğitim amaçlı kullanılan veriler

hangi mevsimde ölçüldüyse, yöntemin bundan sonraki hata yakalama başarısı aynı mevsime ait ölçüm verileriyle karşılaştırıldığında daha yüksek olmaktadır. Bu nedenle araştırmacılar eğitim verilerinin daha çok mevsimsel örnek içerecek şekilde seçilmesini önermişlerdir.

Bonsignore ve arkadaşlarının çalışmasında FV sistemler için uyarlamalı sinirsel-bulanık çıkarsama sistemi (Adapted Neuro-Fuzzy Inference System - ANFIS) temelli bir hata tespit yöntemi sunulmuştur (Bonsignore et al., 2014). Çalışmada ilk önce Matlab/Simulink ortamında bir FV sistem modeli tasarlanmıştır. Tasarlanan bu model değişik güneş ışınımı ve panel çalışma sıcaklığı koşullarında çalıştırılarak sistem çıkışına ait I/V eğrileri elde edilmiştir. Her bir I/V eğrisinden I_{mpp} , V_{mpp} , I_{sc} , V_{oc} olmak üzere 4 ayrı veri elde edilmiştir. Ardından S_1 ve S_2 adıyla iki yeni parametre hesaplanmıştır (Eşitlik 2.3). Hesaplanan iki yeni parametre ile toplamda 6 adet çıkış parametresi elde edilmiştir.

$$S_1 = \frac{I_{mpp} - I_{sc}}{V_{mpp} - V_{oc}} \quad S_2 = \frac{0 - I_{mpp}}{V_{oc} - V_{mpp}} \quad (2.3)$$

FV sistem bu kez ANFIS ile modellenerek, güneş ışınımı ve panel çalışma sıcaklığı giriş, elde edilen 6 parametre ise çıkış parametresi olarak kullanılmıştır. Elde edilen yeni model, bir önceki modelden elde edilen verilerle eğitilerek her türlü çalışma koşulu için doğru I/V eğrilerini verir hale gelmiştir. FV sistemde meydana gelen hatalar, elde edilen I/V eğrilerini etkilemektedir (Şekil 2.2).



Şekil 2.2. I/V eğrisindeki değişimler (Bonsignore et al., 2014).

Normal şartlarda karşılaşılabilecek I/V eğrilerinden, hatanın çeşidine göre farklılıklar arz eden bu sapsmalar 6 ayrı kategoriye ayrılmıştır. Çalışmada, meydana gelebilecek hataların hangi çıkış parametrelerini etkileyeceği ve I/V eğrisini hangi yönde bozacağı açıkça belirtilmiştir.

Ardından 6 adet çıkış parametresinin ideal, normal ve hatalı olmaları durumunda ortaya çıkan sonuçlar sırasıyla X_{id} , X_{nm} , X_{ft} kümeleriyle ifade edilmek üzere, normal ve hatalı veri kümelerinin, ideal olanla farkları (RX) aşağıdaki eşitlikte görüldüğü gibi hesaplanmıştır (Eşitlik 2.4).

$$RX_{id,nm} = X_{id} - X_{nm} \quad RX_{id,ft} = X_{id} - X_{ft} \quad (2.4)$$

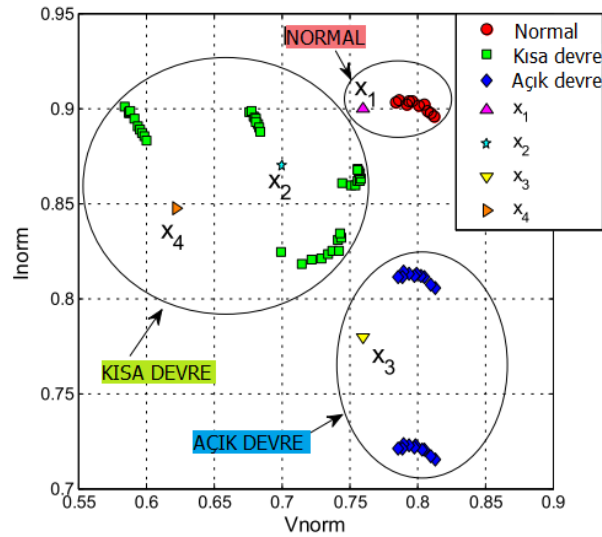
Elde edilen ideal-normal ve ideal-hatalı farkları için iki ayrı Öklid Normu bağıntısı elde edilmiştir (Eşitlik 2.5).

$$|N_n| = \sqrt{\sum_{i=1}^6 (RX_{id,nm})^2} \quad |N_f| = \sqrt{\sum_{i=1}^6 (RX_{id,ft})^2} \quad (2.5)$$

Burada N_n Sinirsel-Bulanık tabanlı FV sistem modelinin ideal şartlar ve normal şartlar için karşılaştırılması ile hesaplanan norm değerinin sayısal değerini ifade ederken, N_f tarafında bu karşılaştırma ideal şartlar ile hatalı şartlar arasında yapılmaktadır. Çalışma ile elde edilen sonuçlara göre normal şartlarda çalışan bir FV sistemin ürettiği N_n norm değeri sıfıra yakın kalmakta ve 0,9 olarak sabitlenen eşik değerini aşmamaktadır. Hatalı çalışan FV sistemlerde ise N_f norm değeri hata tipine göre değişmekle birlikte eşik değerinin hep üzerinde olacak şekilde değerler üretmiştir. Çalışma sonucuna göre; N_f norm değerinin, $1 < N_f < 3$ aralığında diyot kısa devre hatasını, $3 < N_f < 5$ aralığında düşük topraklama hatasını, $5,5 < N_f < 10$ aralığında kısmi gölgelenme hatasını ve $12,5 < N_f < 21$ aralığında yüksek topraklama hatasını işaret ettiği belirtilmiştir.

Zhao ve arkadaşları bir çalışmalarında FV sistemlerde hata tespiti yapabilmek için makine öğrenmesi teknikleri kullanan çalışmaların çoğunlukla gözetimli öğrenme modelleri kullandığını ifade etmişlerdir. Gözetimli öğrenme modellerinin

eđitilmesi için çok sayıda normal ya da hatalı çalışma durumlarından elde edildiđi önceden bilinen etiketlenmiř veri örneđi gerektiđini belirterek, grafik tabanlı yarı gözetimli bir öğrenme modeli önermiřlerdir (Zhao et al., 2015). Yarı gözetimli öğrenme modelinde az miktarda etiketlenmiř veri yeterli olmakta, verinin çođunluđunun etiketlenmemiř olması sorun teřkil etmemektedir. Önerilen model ile gözetimli öğrenmenin gerektirdiđi tamamı etiketlenmiř çok miktarda hassas ölçüm verisi toplamanın beraberinde getirebileceđi zorluklar ve yüksek maliyetin önüne geçilebilmesi düşünölmüřtür. FV sistemlerde normal ve hatalı durumlar birbirlerine yakın akım ve gerilim deđerleri üretebileceđinden bunların birbirlerinden ayrılması zor olabilmektedir. Zhao ve arkadařları çalışmalarında, birbirlerine yakın olan bu normal ve hatalı durumlardan elde edilmiř verileri daha kolay ayırt edebilmek için verilerin yeni bir yöntemle normalleřtirilmesini önermiřler böylece verilerin kümelenebilmesinin ve grafiksel olarak birbirlerinden ayırt edilebilmesinin sađlandığını belirtmiřlerdir. Normalleřtirmenin ardından normalleřtirilmiř akım / normalleřtirilmiř gerilim (I_{norm}/V_{norm}) eđrisi üzerinde bulunan her bir ölçüm veri noktası için eđer bu nokta etiketlenmiř veriyse, bu noktaya yakın olan etiketlenmemiř veri noktalarını da aynı türde etiketleyerek bir kümeleme – sınıflandırma elde edilmiřtir (řekil 2.3).



řekil 2.3. Etiketlenmiř verilerin kümelenebilmesi (Zhao et al., 2015).

Böylelikle normal ya da hatalı çalışma durumlarına ait olup olmadıđı bilinmeyen ölçüm verileri hangi etiketlenmiř (normal ya da hatalı çalışma

durumlarında ölçüldüğü bilinen) veriye yakınsa o türde etiketlenerek yeni sınıfına dâhil olacaktır. Bu sınıflar normal çalışma, kısa devre hatası ve açık devre hatası sınıflarıdır. Gölgeleme hataları çalışma kapsamı dışında bırakılmıştır. Çalışma sonucu elde edilen model, kendi kendine öğrenerek değişen hava durumları, güneş panellerinin eskimesi gibi farklı koşullarda elde edilen verileri etiketleyebilmektedir.

Mekki ve arkadaşları çalışmalarında, kısmi gölgeleme altındaki FV panelin üreteceği çıkış gerilimi ve akımını tahmin edebilen ve böylelikle hata durumunu yakalayabilen YSA tabanlı bir yöntem geliştirmişlerdir (Mekki et al., 2016). Kullandıkları bir veri toplama sistemi aracılığıyla 30 gün boyunca, güneş ışınımı, FV panel sıcaklığı, panel çıkış gerilimi ve akımı ölçülmüştür. Ölçüm veri seti yaklaşık 3000 kayıttan oluşmaktadır. Veri setinin %70'lik kısmı YSA'nı eğitmek, %30'luk kısmı ise test etmek amaçlı olarak kullanılmıştır. Önerilen YSA, veri setindeki güneş ışınımı ve panel sıcaklığı verilerini giriş parametreleri, panelin çıkış gerilimi ve akımı değerlerini de çıkış parametreleri olarak kullanmaktadır. Hem giriş hem de çıkış parametreleri [-1, +1] aralığında normalleştirildikten sonra YSA, esnek geri yayılım (Resilient Back-Propagation – RBP) algoritması ile eğitilmiştir. Eğitilen ağın performansının önemli bir ölçütü, ağın tahmin ettiği çıkış değerleri ile ölçüm sonucu elde edilen gerçek çıkış değerleri arasındaki korelasyonu gösteren regresyon (R) değeridir. R değerinin 1'e yakın olması ağın tahmin ettiği değerler ile gerçek değerler arasında yakın bir ilişki olduğunu gösterir. Bir diğer performans ölçütü ise ağın tahmin ettiği değerler ile gerçek değerler arasındaki farkın karelerinin ortalaması (Mean Squared Error – MSE) değeridir. Bu değer düşük olması hatanın da düşük olduğunu gösterir. MSE değeri 0 ise hata yok demektir. Geliştirilen modelde ağ performans değerleri olarak $R=0,99964$, $MSE=0,00101$ elde edilmiştir. FV panellerin üzerine gölge düştüğü durumlarda panel çıkış gücünde kayıplar oluşmaktadır. Bu hata durumunun tespiti için bu çalışmada önerilen yöntem, ölçülen gerçek değerler ile YSA tarafından tahmin edilen değerler arasındaki farkın belirli bir eşik değerini aşıp aşmadığının kontrolü şeklinde çalışmaktadır. Farklı kısmi gölgeleme durumlarını test etmek için 72 hücreden oluşan BP150SX güneş panelinin sırasıyla 5, 8, 10, 18, 25, 30 ve 50 adet hücresi üzerine aynı yoğunlukta gölge düşecek şekilde kurgulanmış bir test düzeneği oluşturulmuştur. Bu düzende yer alan, kısmi olarak gölgeleme panelinden gerilim

ve akım deęerleri 1 gnlk sre boyunca llerek toplanmıřtır. Gn boyunca llen akım ve gerilim deęerleri, normal alıřma řartları verileriyle daha nceden eęitilmiř YSA tahmin deęerleri ile karřılařtırılarak ortalama mutlak hata (Mean Absolute Error – MAE) ařaęıdaki Eřitlik 2.6’da gsterildięi gibi hesaplanmıřtır.


$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - y_i^*| \quad (2.6)$$

Bu deęer her glgelenme senaryosu iin ayrı ayrı elde edilmiřtir. Eřitlik 2.6’da y_i llen gerilim veya akım deęerlerini, y_i^* tahmin edilen gerilim veya akım deęerlerini, N ise rnek sayısını gstermektedir.

Normal alıřma řartlarında yani hibir FV hcre zerine glge dřmyorken MAE deęeri 0’a yakın ıkmaktadır. Hatalı alıřma řartlarından ilkini temsilen 5 FV hcrenin zerine glge dřrldęnde, MAE deęerleri akım ve gerilim iin sırasıyla 0,0667A ve 1,71V ıkarken R deęeri yaklařık 0,9 olarak elde edilmiřtir. Aynı řekilde 25 adet glgelenmiř hcre iin MAE deęerleri akım ve gerilim iin sırasıyla 0,3719A ve 8,28V, R deęeri yaklařık 0,6 olarak elde edilmiřtir. 50 adet hcrenin glgelendięi durumda ise MAE deęerleri akım ve gerilim iin sırasıyla 0,52A ve 11,47V olarak elde edilirken, R deęerinin ise 0,5’ten kk olarak tespit edilmiřtir. Elde edilen sonuca gre llen ve tahmin edilen akım/gerilim deęerleri arasındaki ortalama mutlak hata deęeri olan MAE ile glgelenmiř FV hcre sayısı arasındaki iliřki ařaęıdaki řekilde basite formle edilebilir (Eřitlik 2.7).

$$MAE = aNSC + b \quad (2.7)$$

Yapılan alıřmada, FV panel teknolojisine gre deęiřmekle birlikte, a ve b katsayıları FV panelin ıkıř akımı iin sırasıyla 0,02 ve -0,013, gerilim iin sırasıyla 0,45 ve -18 olarak bulunmuřtur (řekil 2.4). alıřmada geliřtirilen YSA tabanlı modelin, karmařık matematiksel hesaplamalar olmadan FV panel ıkıř deęerlerini doęru olarak tahmin edebileceęi ve ıkıř gcnde herhangi bir dřř tespit edebileceęi gsterilmiřtir. Bununla birlikte aęın ıkıř deęerlerini yksek doęrulukla tahmin edebilmesi iin periyodik olarak eęitilmesi nerilmiřtir.




Şekil 2.4. Gölgeleşmiş hücre sayısına göre MAE değerleri (a) Akım, (b) Gerilim (Mekki et al., 2016).

Chine ve arkadaşlarının çalışmasında FV sisteme ait akım, gerilim ve I/V eğrisindeki tepe noktalarının sayısını temel alan bir hata tespit ve teşhis tekniği önerilmiştir (Chine et al., 2016). Bir FV dizide meydana gelebilecek 8 ayrı tip hatanın tespit edilebilmesi hedeflenmiştir. Bu hatalara 1'den 8'e kadar numaralar verilmiş olup her biri farklı bir hata türünü simgelemektedir. Çalışmada hatayı tespit eden ve bu hatanın kaynağını belirleyen iki ayrı algoritma geliştirilmiştir (Şekil 2.5). Hata tespiti, FV dizi çıkış gücünün ölçülen değeri ile benzetimi yapılan değeri arasındaki farkın belirli bir eşik değeri ile karşılaştırılması şeklinde çalışmaktadır. Hatanın tipi ve kaynağının ortaya çıkarılması ise FV dizinin I/V karakteristiğinin analiziyle gerçekleştirilmektedir. Çalışmada bahsi geçen FV dizi benzetimi Matlab/Simscape aracı ile gerçekleştirilmiş olup, FV hücreyi temel alan güneş paneli, akım ve gerilim algılayıcıları ve diğer gerekli elektronik elemanları temsil eden Simscape blokları kullanılmıştır.

Gerçekleştirilen benzetimden elde edilen I/V eğrisi analiz edilmiştir. Analiz sonucunda, sistemde ortaya çıkabilecek hata sinyalleri sırasıyla kısa devre akımındaki azalma, açık devre gerilimindeki azalma, çıkış akımında azalma veya artma, çıkış geriliminde azalma veya artma, I/V eğrisindeki maksimum güç noktası (Maximum Power Point – MPP) sayısındaki artma şeklinde belirtilerek sırasıyla C1, V1, C2, V2 ve N şeklinde adlandırılmıştır. Bu durumların tek başına ya da birkaçının bir arada gerçekleşmesi, FV sistemin normal ya da belirli hatalarla çalıştığını belirtmektedir. Çalışmada elde edilen sonuçlara göre bazı farklı hatalar

aynı hata sinyallerini üretebilmekte ya da bir hata farklı hata sinyalleriyle kendini tekrar edebilmektedir.



Şekil 2.5. Hata tespiti ve sınıflandırma yöntemi (Chine et al., 2016).

Sunulan model ilk olarak algoritma 1'i çalıştırarak DAQ sistemi üzerinden güneş ışınımı ve panel çalışma sıcaklığı bilgilerini toplayarak bu bilgileri gerçek sistemle karşılaştırılacak benzetim modeline taşır. Benzetim modelinden elde edilen akım ve gerilim verileri, algılayıcılarla okunan gerçek sisteme ait akım ve gerilim verileriyle karşılaştırılır. Elde edilen iki veri seti arasındaki fark, modelin belirsizlik ve ölçüm hatalarına karşı önlem olarak kullandığı eşik değeri ile karşılaştırılır. Eğer fark bu eşik değerinden küçük ise sistem çalışması normal seviyededir fakat fark eşik değerinden büyük ise hataların sınıflandırıldığı algoritma 2 çalıştırılır. Farkın eşik değerinden büyük olmasının sebepleri algoritma 1 tarafından panellerin açık devre olması, bağlantı hatası, kısmi gölgeleme gibi sebepler olarak not edilir. Fakat hatanın tam olarak sınıflandırılması ikinci algoritma tarafından gerçekleştirilir. Algoritma 2 için bir YSA modeli geliştirilmiştir. YSA'nı eğitmek için gerekli olan etiketlenmiş veriler FV dizi benzetiminden elde edilmiştir. Bunun için tüm hataların birer benzetimi yapılarak elde edilen veriler toplanmıştır. En etkili hata sınıflandırmasını yapabilmek için çok katmanlı perseptron (Multi-Layer Perceptron – MLP) ve dairesel tabanlı fonksiyon (Radial Basis Function – RBF) modelleri karşılaştırmalı olarak kullanılmıştır. MLP modelinde Levenberg - Marquardt (LM) öğrenme algoritması kullanılmıştır. Karşılaştırma sonucu, MLP modelinin sınıflandırma işleminde RBF modelinden

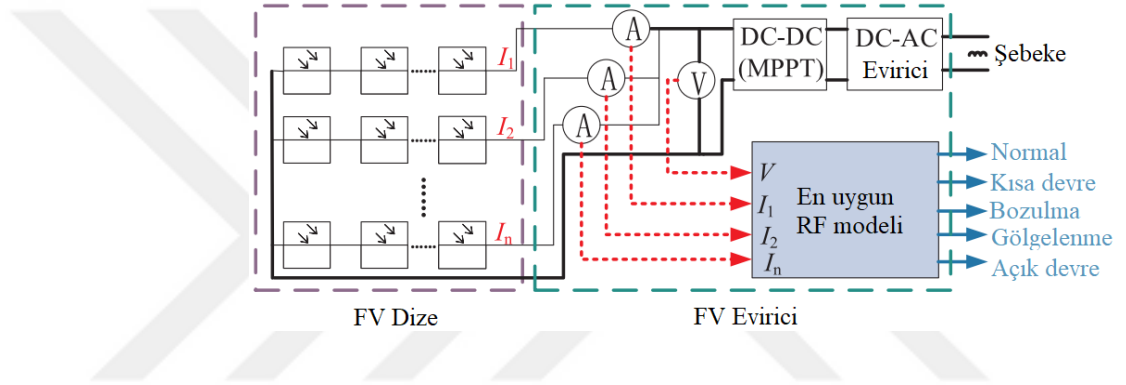
üstün olduğunu göstermiştir. Çalışmada ortaya konan teknik Alanda Programlanabilir Kapı Dizileri (Field Programmable Gate Array – FPGA) üzerinde uygulanarak çalışan bir ilk örnek elde edilmiştir.

Yukarıda bahsi geçen çalışmalar gibi literatürde sık rastlanan, ölçümlerin, beklenen değerlerle karşılaştırılmasına dayanan hata tespit yöntemleri, genel olarak olası hata durumunda uyarılmak için doğru bir eşik değerinin seçilmesini gerektirmektedir. Eşik belirleme yaklaşımı ise deneme yanılma şeklinde belirlenebilir veya FV sistem tasarımı uzmanlığını gerektirir.

Yukarıda da belirtildiği üzere literatürde yer alan FV sistemler için yapay zekâ temelli hata tespiti çalışmalarında tek bir öğrenme algoritmasına dayalı hata tespit yöntemleri kullanılmıştır. Fakat bu yaklaşım kullanılan öğrenme algoritmasının yetenekleriyle sınırlı kalmaktadır. Bununla birlikte, son yıllarda pek çok alanda daha sık kullanılmaya başlanan topluluk öğrenmesi yöntemi, tek bir öğrenme algoritmasının genelleme yapma yeteneğinin ve sağlamlığının üzerine çıkabilmek için farklı modellerin yeteneklerini birleştirebilmektedir. Her ne kadar bu yaklaşım hem özellik seçimi hem de parametre optimizasyonu uzmanlığı gerektirse de, uygun özellikler seçildikten sonra, aday öğrenme algoritmalarını birleştirecek topluluk öğrenmesi modelinin sınıflandırma performansı, parametre optimizasyonu ile en üst düzeye çıkarılabilir. Topluluk öğrenmesine dayalı yöntemler, FV sistemleri dışında farklı alanlarda da aykırı değer algılama veya hata tespitinde kullanılmışlardır (Wang et al., 2018). Ayrıca, FV enerji üretimi tahmininde topluluk öğrenmesi tabanlı yöntemlere dayanan çalışmalar vardır (Ahmad et al., 2018; Pierro et al., 2016; Rana et al., 2015).

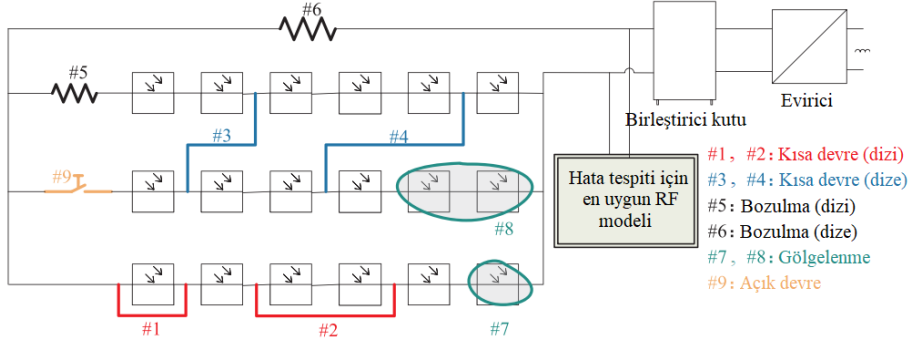
Chen ve arkadaşları çalışmalarında, FV sistemlerde hata tespiti için sadece karar ağaçlarından oluşan bir topluluk öğrenmesi modeli olan rastgele orman modelinin kullanıldığı bir hata tespit sistemi önermişlerdir (Chen et al., 2018). Araştırmacılar, tek bir öğrenme algoritmasının kullanıldığı geleneksel hata tespit yöntemlerinin çoğunda aşırı uyumlanma (overfitting) probleminin yaşandığını ve sistemin genelleme yeteneğinin kullanılan öğrenme algoritması ile sınırlı kaldığını belirtmişlerdir. Bu genelleme yeteneğinin üzerine çıkabilmek için, çok sayıda karar ağacının, orijinal eğitim verilerinden örneklenen farklı veri kümeleri ile eğitildiği

rastgele orman modeli kullanarak tek bir karar ağacından daha yüksek genelleme performansı elde etmişlerdir. Çalışmada FV sistemlerdeki kısa devre, açık devre, eskime ve gölgelenme durumlarının tespit edilebilmesi hedeflenmiştir. Çalışmada ilk önce Matlab/Simulink ortamında bir FV sistem modeli tasarlanmış ve bu model $100 W/m^2 - 1000 W/m^2$ arasında değişen ışınım şiddeti ve $10^{\circ}C - 80^{\circ}C$ arasında değişen hücre sıcaklığı koşullarında normal çalışma ve hatalı çalışma senaryolarında çalıştırılarak her FV dizinin çıkış akımları ile tüm sistemin çıkış gerilimi elde edilmiştir. Önerilen yöntemde FV sistemin benzetimi yapılırken kullanılan güneş ışınımı ve hücre sıcaklığı değerleri hata tespitinde kullanılmamıştır (Şekil 2.6).



Şekil 2.6. Rastgele orman modeli hata tespit yöntemi (Chen et al., 2018).

Çalışmada FV sistem benzetimi üzerinde hata senaryoları şu şekillerde canlandırılmıştır. Kısa devre hata senaryoları, FV dizideki bir panelin kısa devre edildiği senaryo ve iki ayrı FV dizi arasında kısa devrenin olduğu senaryo şeklinde gerçekleştirilmiştir. Gölgelenme hata senaryoları, bir panel üzerine düşen ışınım şiddetinin diğerlerinden %20 ve %30 daha az olduğu şekillerde gerçekleştirilmiştir. Eskime senaryoları, FV dizideki iki panel arasında ve tüm sistemin çıkışına 4Ω değerli bir direncin seri olarak eklenmesi şeklinde gerçekleştirilmiştir. Son olarak FV sistem benzetimindeki açık devre hata senaryoları ise FV dizi çıkışına sonsuz değerli bir direncin seri olarak eklenerek o dizinin FV sistemden koparılması şeklinde gerçekleştirilmiştir (Şekil 2.7).



Şekil 2.7. Hata senaryoları benzetim şeması (Chen et al., 2018).

Benzetim sonucunda elde edilen verilerin %75'i rastgele orman modelini eğitmek için, %25'i ise eğitilmiş modelin daha önce hiç karşılaşmadığı veriler için genelleme yapma yeteneğini test etmek amacıyla kullanılmıştır. Rastgele orman modelinin içerdiği karar ağacı sayısı için 1-500 arasında değerler denenerek en iyi sonucu veren karar ağacı sayısı bulunarak model optimize edilmiştir.

Araştırmacılar, önerdikleri yöntemin deneysel geçerliliğini test etmek amacıyla 2kW gücünde bir FV sistem üzerinde, sistem benzetiminde yaptıkları hata senaryolarını canlandırarak DAQ sistemi aracılığıyla veri toplamışlardır. Toplanan veriler, FV sistemin normal ve hatalı koşullarda çalıştığını ifade eden sınıf isimleriyle sınıflandırılmışlar diğer bir deyişle etiketlenmişlerdir. Daha sonra elde edilen bu veri seti yine %75 / %25 oranlarında bölünerek rastgele orman modelinin sırasıyla eğitilmesi ve test edilmesi için kullanılmıştır. Rastgele orman modeliyle karşılaştırmak için yukarıda yapılan tüm işlemler bağımsız olarak tek bir karar ağacı modeli ile aynı veri setlerini kullanarak tekrar edilmiştir. Her iki modelden elde edilen sonuçlara göre hata tespiti için rastgele orman modeli hem benzetim hem de gerçek ölçüm veri setlerinde karar ağacından daha iyi tahmin doğruluğu elde etmiştir. Bununla birlikte hem rastgele orman modeli hem de karar ağacı modeli gerçek ölçüm veri setinde, benzetim veri setinden çok az da olsa düşük bir başarı elde etmişlerdir. Araştırmacılar bu farkın gerçek ölçümlerden elde edilen verilerin gürültü içermesinden kaynaklandığını belirtmişlerdir.

Sonuç olarak araştırmacılar tek tip öğrenme algoritmasından (karar ağacı) oluşsa da, bir topluluk öğrenmesi yöntemi olan rastgele orman modelinin içerdiği

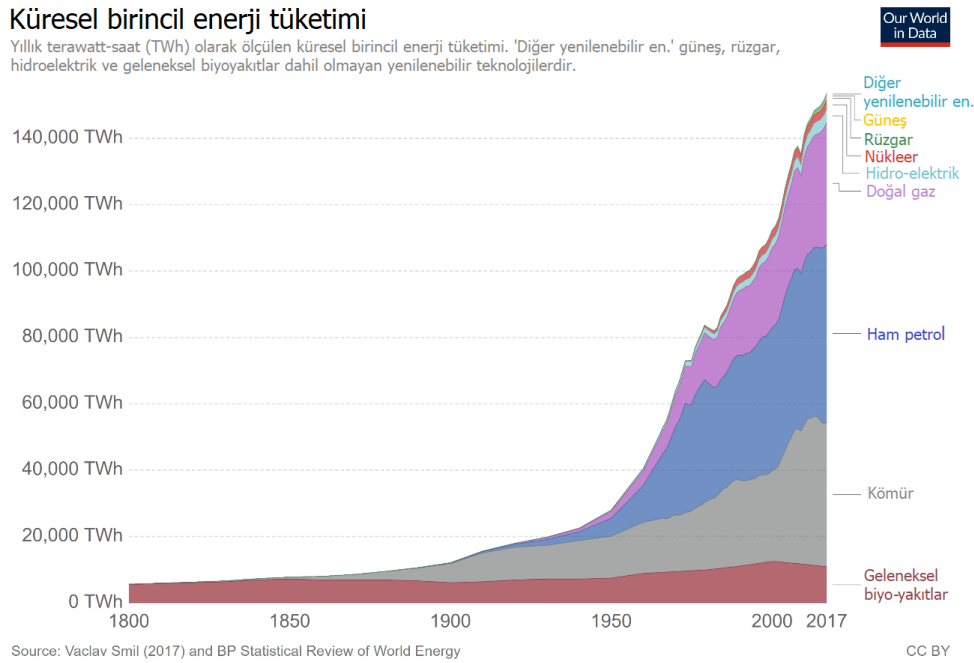
tüm karar ağaçlarının tahminlerini birleştirerek, tek bir algoritmanın genelleme yapma yeteneğinin ve sağlamlığının üzerine çıkabileceğini göstermişlerdir.

Yukarıda bahsi geçen çalışmaların dışında, literatürde hatanın tespiti, sınıflandırılması ve hata yerinin tespiti konularında, yapay zekâ teknikleri kullanılan pek çok çalışma mevcuttur. Bu çalışmalardan karar ağacı temelli (Zhao et al., 2012), bulanık mantık temelli (Mansour et al., 2015; Spataru et al., 2015), YSA temelli (Akram and Lotfifard, 2015; K. Chao et al., 2014; Jiang and Maskell, 2015; Jones et al., 2015; Karatepe ve Hiyama, 2011), uzman sistemler temelli (Yagi et al., 2003), aykırı değer algılama kuralları temelli (Zhao et al., 2014), uzatma sinir ağı temelli (K. H. Chao et al., 2008; Hsieh et al., 2014) çalışmalardır. Bu çalışmaların dışında, matematiksel, istatistiksel, termografi, resim işleme teknikleri kullanarak hata tespiti yapan çalışmalar da vardır.

Bu tez çalışmasında, FV izleme sistemlerinde yaygın olarak kullanılan yapay zekâ temelli hata tespit sistemlerindeki geleneksel yaklaşım olan tek bir makine öğrenme algoritması kullanılmasından farklı olarak, birden fazla öğrenme algoritmasının yeteneklerinin birleştirildiği topluluk öğrenmesi yöntemi kullanılmıştır. Bununla birlikte hata tespitini yapan topluluk öğrenmesi yöntemi, bulut bilişim katmanında çalıştırıldığından hem hata tespiti, hem veri saklama, hem de veri izleme sistemlerinin çalıştırılması için farklı fiziksel donanımlara olan gereksinim ortadan kaldırılmıştır.

3. FV GÜÇ SİSTEMLERİ


Güneş enerjisi, dünya çapında giderek artan enerji tüketimi (Şekil 3.1) ve hızla azalan birincil enerji kaynakları sebebiyle iyi bir alternatif enerji kaynağı olan yenilenebilir enerji kaynaklarından biridir. Bununla birlikte erişimi en kolay ve bildiğimiz evrendeki en büyük enerji kaynağıdır. Bu büyük enerji, kabaca tüm dünyada ihtiyaç duyulan enerjinin 1000 katını karşılayabilse de bu enerjinin sadece %0,02 gibi çok küçük bir kısmı kullanılabilir (Devabhaktuni et al., 2013).



Şekil 3.1. Dünya birincil enerji kaynaklarının tüketimi (Vaclav Smil, 2017).

Global elektrik enerjisi üretiminde yenilenebilir enerjinin payı giderek artsa da güneş enerjisinden elektrik enerjisi üretimi henüz düşük seviyededir (Şekil 3.2). Bununla birlikte artan dünya nüfusuyla birlikte elektriğe erişim imkânı bulan insan sayısı da sürekli artmaktadır (Şekil 3.3). Bu nedenle elektrik enerjisi üretiminde yenilenebilir enerjinin payının artırılması hava kirliliği ve küresel ısınma tehlikesinin azaltılması hedefiyle de örtüşmektedir.


Yenilenebilir Enerjinin Küresel Elektrik Üretimindeki Tahmini Payı, 2017-Sonu



Şekil 3.2. Yenilenebilir enerji kaynaklarının dünya çapında elektrik üretimindeki tahmini payı (Renewables 2018 Global Status Report, 2018).

Elektriğe erişimi olan/olmayan insan sayısı

Belli bir nüfustaki elektriğe erişimi olan ve olmayan insan sayısı.




Source: The World Bank, World Development Indicators (WDI) and UN Population Prospects
OurWorldInData.org/energy-production-and-changing-energy-sources/ • CC BY

Şekil 3.3. Dünya üzerinde elektriğe erişimi bulunan insan sayısı (World Bank World Development Indicators, 2017).

Güneş enerjisi FV paneller, yoğunlaştırılmış güneş enerjisi (Concentrated Solar Power - CSP), yoğunlaştırılmış fotovoltaiik (Concentrated Photovoltaics - CPV) gibi farklı teknolojiler kullanılarak elektrik enerjisine çevrilebilir. Bu teknolojiler arasında en iyi bilineni FV panellerdir. FV teknolojisi, güneş ışığından

direkt elektrik enerjisinin üretilebildiği bir teknolojidir. Bu bölümde FV teknolojisinin ürünü olan FV paneller ve bu panellerden oluşan güç sistemleri ele alınacaktır.

FV sistemlerin temelinde FV hücreler vardır. Şekil 3.4'te bir FV hücrenin yapısı görülmektedir. En yaygın kullanılan FV hücreler yarı-iletken silisyum hücrelerdir. Yarı-iletken FV hücreler yüzeylerine gelen güneş ışığındaki ışık tanecikleri olan fotonları fotovoltaiik etki ile elektrik enerjisine çeviren yarı-iletken malzemelerdir. Kristal yapıdaki bir silisyum atomu, ışığa maruz kaldığında, bu ışıktaki bir fotonu alır. Eğer fotonun enerjisi belli bir eşik değerinden yüksekse, atomun değerlik bandındaki zayıf bağlanmış elektronlardan biri serbest kalarak iletim bandına geçer. Fotonlar sayesinde serbest kalan elektronların iletim bandından dış devreye bir elektrik akımı oluşturması elektrik enerjisi üretimine neden olur. Fotonlardaki enerjinin elektron oluşturmak için gereken miktardan fazla olan kısmı ise ısıya dönüşür. Yarı-iletken FV hücrelerde malzeme olarak silisyum haricinde galyum arsenit (GaAs), kadmiyum tellür (CdTe), kadmiyum sülfür (CdS) gibi anorganik malzemeler de kullanılmaktadır (Duffie and Beckman, 2013).




Şekil 3.4. FV hücre yapısı (Sampaio and González, 2017).

Yarı-iletken malzemeler, saf eriyik haldeyken içlerine istenilen katkı maddelerinin kontrollü olarak eklenmesiyle n ya da p tipi katkılanmış hale gelirler. Bu katkılanma işlemi yarı-iletkenin FV hücre olarak kullanılabilmesi için gereklidir. Hangi tipte yarı-iletken olacağı katkı maddesine bağlıdır. Dış yörüngesinde 5 elektron olan fosfor gibi periyodik cetvelin 5. grubundan bir elementle katkılanmış silisyum, n tipi silisyum haline gelir. Periyodik cetvelin 4.

grubundaki silisyumun dış yörüngesinde 4 elektron olduğundan fosforun fazla olan 1 elektronu kristal yapıya bir elektron vererek n tipi hale getirir. Benzer şekilde periyodik cetvelin 3. grubundan olan bir elementle katkılanmış silisyum ise bu sefer kristal yapıda meydana gelen 1 elektron eksikliğinden dolayı p tipi silisyum haline gelecektir. Elde edilen p ya da n tipi malzemeden yarı-iletken eklemeler oluşturulur. Örneğin p-n tipinde bir eklemede, n tipi taraftaki çoğunluk taşıyıcı elektronlar p tarafına doğru ikisi arasında denge sağlanana kadar akım oluştururlar.

FV hücrelerin çıkışları doğrusal olmayan bir şekilde üzerlerine düşen ışınım şiddeti ve hücre çalışma sıcaklığına bağlı olarak değişirler. FV hücrelerin bu davranışlarını modellemek için en çok kullanılan yöntem tek diyotlu elektriksel eşdeğer devresi kullanmaktır (Celik ve Acikgoz, 2007; Chouder et al., 2012; De Blas et al., 2002; Lo Brano et al., 2010; Orioli and Di Gangi, 2013; Villalva et al., 2009; G. Wang et al., 2017). Şekil 3.5'te tek diyot modelinin elektriksel eşdeğer devresi görülmektedir.



Şekil 3.5. Tek diyot modelinin elektriksel eşdeğer devresi.

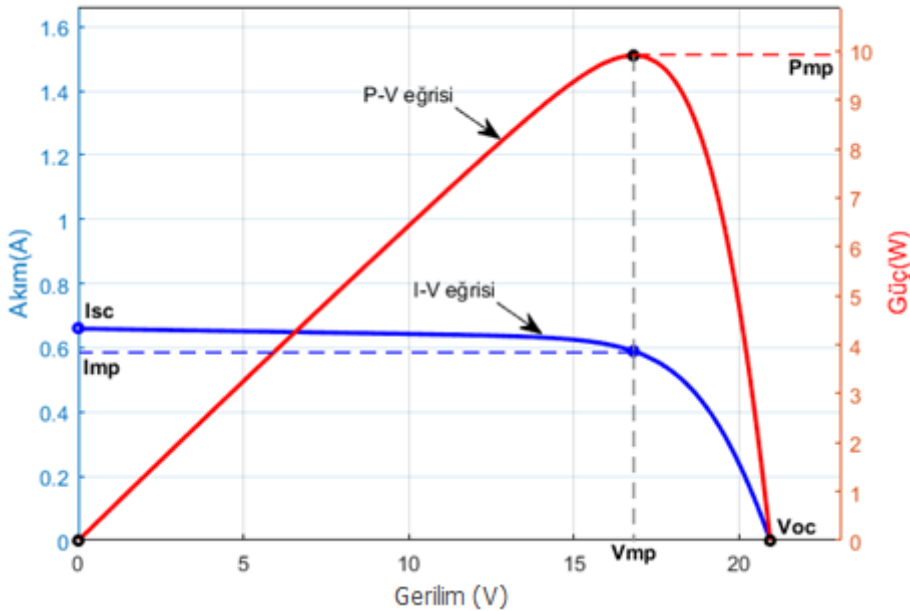
Tek diyot modeli, bir p-n eklem diyotu, bu diyota paralel bağlı bir direnç (R_p), bir seri direnç (R_s) ve bir akım kaynağından (I_L) oluşmaktadır. FV hücresinin ürettiği akım modelde I_L ile ifade edilir. Bu modelin sabit ışınım ve hücre sıcaklığındaki I-V karakteristiği aşağıdaki iyi bilinen eşitlik ile ifade edilir (Arab et al., 1999; Bai et al., 2014; Celik ve Acikgoz, 2007; Chouder et al., 2012; De Blas

et al., 2002; De Soto et al., 2006; Duffie and Beckman, 2013; Lo Brano et al., 2010; Orioli and Di Gangi, 2013; Villalva et al., 2009):

$$I = I_L - I_D - I_{R_p} = I_L - I_o \left[\exp \left(\frac{V + IR_s}{V_t a} \right) - 1 \right] - \frac{V + IR_s}{R_p} \quad (3.1)$$

Burada I_L foton akımı, I_D diyot üzerinden geçen akım, I_{R_p} paralel direnç R_p üzerinden geçen akımdır. Kirşof'un akımlar kanununa göre $I_L - I_D - I_{R_p}$ eşitliğinin sonucu hücre çıkışında elde edilen akımı verir. Eşitlikteki I_o diyotun ters doygunluk akımı, a diyot ideal faktörü, $V_t = N_s kT/q$ diyotun termal gerilimi, N_s FV paneldeki seri bağlı hücre sayısı, k Boltzmann sabiti ($1.3806503 \times 10^{-23} \text{ J/K}$), T hücre sıcaklığı (Kelvin) ve q elektron yüküdür ($1.60217646 \times 10^{-19} \text{ C}$).

Şekil 3.6'da FV panele ait tipik I-V ve P-V eğrileri görülmektedir. I-V eğrisinde gerilimin 0 olduğu noktada, akım y eksenini kısa devre akımı (I_{sc}) noktasında keser. Benzer şekilde aynı eğri akımın 0 olduğu noktada, x eksenini açık devre gerilimi (V_{oc}) noktasında keser.



Şekil 3.6. FV panele ait tipik I-V ve P-V eğrileri.

FV hücrenin çıkış karakteristiği, üzerine düşen ışınım şiddeti ve hücre sıcaklığına bağlı olarak doğrusal olmayan bir şekilde değiştiğinden, FV hücrenin

çıkış akımında etkisi olan I_L ve I_o akımları da farklı çalışma koşullarında değişiklik gösterirler (Eşitlikler 3.2 ve 3.3) (Celik ve Acikgoz, 2007; Chin et al., 2015; De Soto et al., 2006; Villalva et al., 2009; G. Wang et al., 2017). Bahsedilen bu çalışma koşulları, standart test koşullarından (Standard Test Conditions - STC) farklı olabilir. STC, 1000 W/m^2 güneş ışınımı ile 25°C hücre sıcaklığını ifade eder.

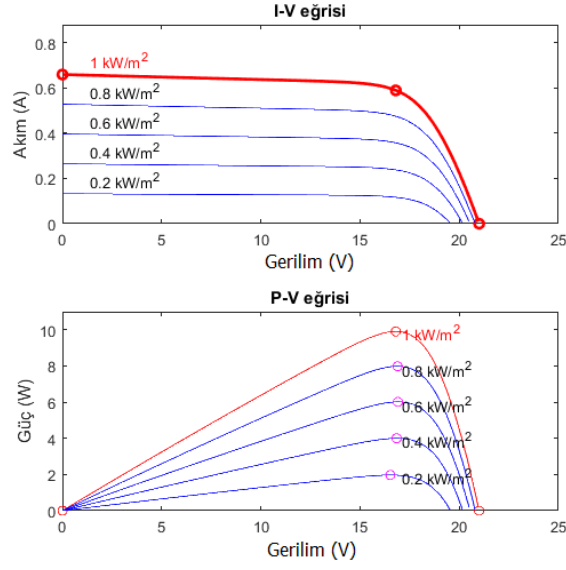
$$I_L = [I_{Ln} + K_i(T - T_n)] \frac{G}{G_n} \quad (3.2)$$

Burada I_L çalışma şartlarındaki foton akımı, I_{Ln} STC koşullarındaki foton akımı, K_i FV panelin kısa devre akım sıcaklık katsayısı ($\text{A}/^\circ\text{C}$), T çalışma şartlarındaki hücre sıcaklığı, T_n STC koşullarındaki hücre sıcaklığı (25°C), G çalışma şartlarında hücre üzerine düşen güneş ışınımı, G_n ise STC koşullarındaki güneş ışınımıdır (1000 W/m^2).

$$I_o = \frac{I_{scn} + K_i(T - T_n)}{\exp\left(\frac{V_{ocn} + K_v(T - T_n)}{aV_t}\right) - 1} \quad (3.3)$$

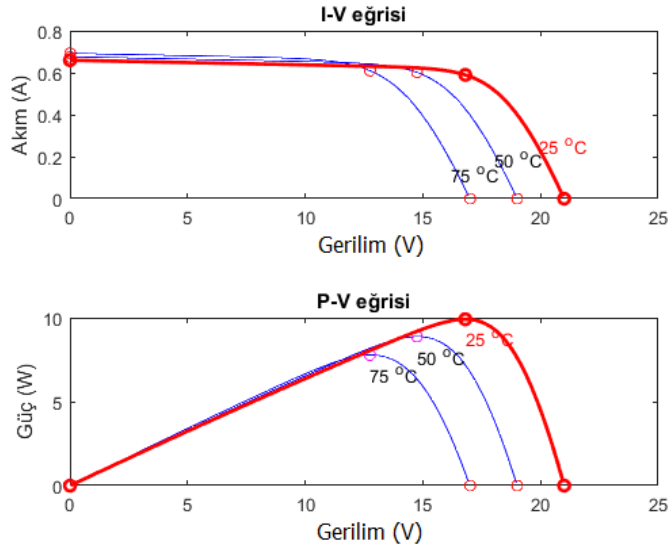
Burada ise I_o çalışma şartlarındaki diyot ters doyumluk akımı, I_{scn} FV panelin STC koşullarındaki kısa devre akımı, V_{ocn} FV panelin STC koşullarındaki açık devre gerilimi, K_v FV panelin açık devre gerilim sıcaklık katsayısıdır ($\text{V}/^\circ\text{C}$).

Eşitlikler 3.2 ve 3.3'e göre farklı çalışma koşullarında değişen çıkış karakteristiğine bağlı olarak I-V ve P-V eğrilerindeki değişim Şekil 3.7 ve Şekil 3.8'de gösterilmiştir. Şekil 3.7'de hücre sıcaklığı 25°C 'de sabit iken, 1000 W/m^2 , 800 W/m^2 , 600 W/m^2 , 400 W/m^2 ve 200 W/m^2 ışınım şiddetlerinde değişen I-V ve P-V eğrileri görülmektedir. Işınım şiddetinin düşmesiyle FV panelin ürettiği akım değeri kayda değer oranda düşerek, çıkış gücünü düşürmektedir. Işınım şiddetinin düşmesi FV panelin çıkış gerilimini düşürse de bu düşüş akımdaki kadar fazla değildir.



Şekil 3.7. I-V ve P-V eğrilerinin ışınımına göre değişimi.

Şekil 3.8’de ise ışınım şiddeti 1000 W/m^2 ’de sabit iken, 25°C , 50°C ve 75°C hücre sıcaklıklarında değişen I-V ve P-V eğrileri görülmektedir. Hücre sıcaklığının artmasıyla FV panelin ürettiği akım değeri çok az miktarda artmaktadır. Fakat FV panelin çıkış gerilimi önemli oranda düştüğünden bu durum çıkış gücünü düşürmektedir.



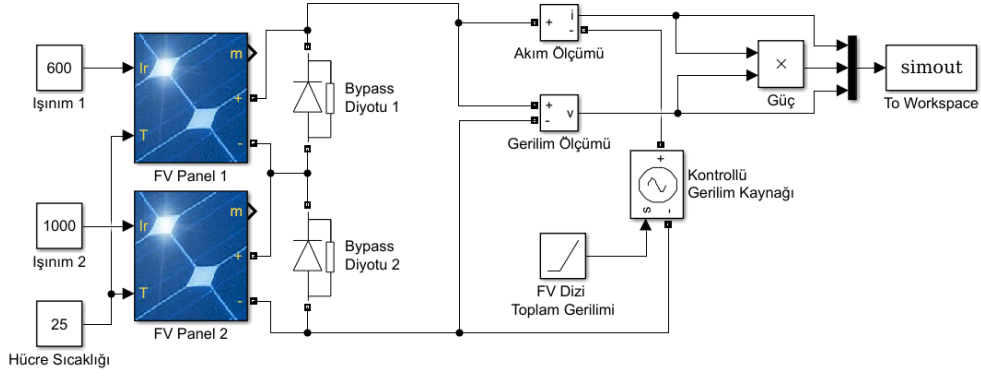
Şekil 3.8. I-V ve P-V eğrilerinin hücre sıcaklığına göre değişimi.

FV panellerde ışınım ve hücre sıcaklığının yanında sistem çıkışına bağlı olan yükün empedansı da güç çıkışını etkilemektedir. Çünkü FV hücreler kendilerine bağlı olan yükün karakteristiğine uygun gerilim ve akım değerlerinde çalışırlar. Bu nedenle FV panellerden her koşul altında en yüksek gücü elde etmek için MPPT yeteneği olan DC-DC dönüştürücüler kullanılmaktadır.

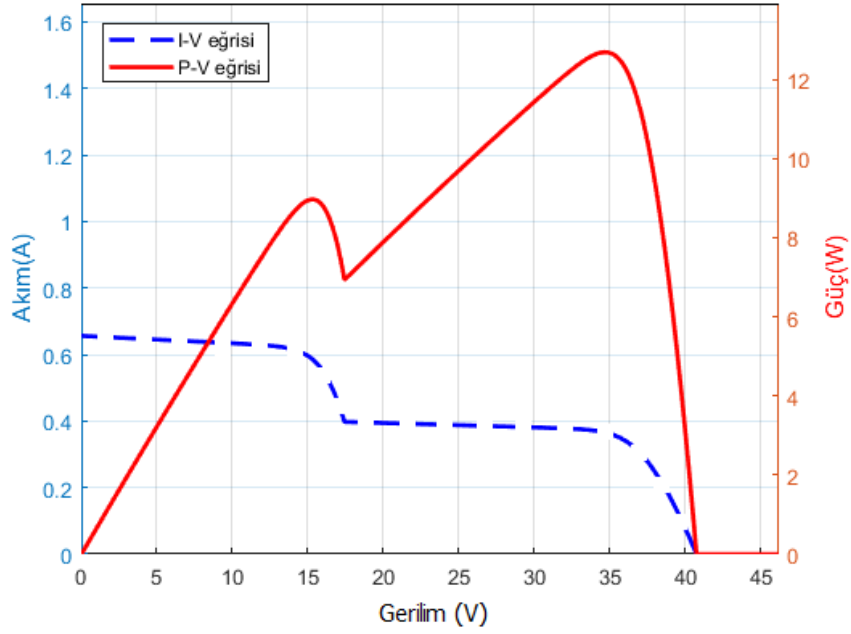
FV hücrelerin ihtiyaca göre seri ve paralel bağlanması FV panelleri oluşturur. Hücrelerin seri bağlanması tıpkı seri bağlı piller gibi sistem çıkışındaki gerilimi arttırırken, paralel bağlanması ise çıkış akımını arttırır. FV panellerinin seri şekilde bağlanmasıyla FV bir dizi elde edilmiş olur. Ulaşılmak istenen güce göre çok sayıda FV dizi birbirine paralel bağlanabilir.

FV dizilerdeki tüm seri bağlı paneller her zaman eşit ışınımına maruz kalmayabilir. Panellerin bir veya birkaçına fiziksel engeller (yaprak, kar gibi), gölgelenme, tozlanma, kirlilik gibi nedenlerle daha az ışınım düşebilir. Şekil 3.9'da Matlab/Simscape¹ kütüphanesindeki FV sistem bileşeni kullanılarak yapılmış benzetim modeli görülmektedir. Şekilde görüldüğü gibi iki FV panelin seri bağlanmasıyla oluşturulmuş dizideki panellerden biri $600 W/m^2$ diğeri ise $1000 W/m^2$ ışınım göreceği şekilde ayarlanmıştır. Her iki panel için hücre sıcaklıkları ise aynıdır ve $25^\circ C$ 'ye ayarlanmıştır. Model bu şekilde çalıştırıldığında Şekil 3.10'daki I-V ve P-V eğrileri elde edilir. Benzetim sonuç olarak bir FV dizideki kısmi gölgelenmenin etkilerini göstermektedir. MPPT yetenekli bir DC-DC dönüştürücü P-V eğrisindeki iki tepe güç noktasından en büyüğünü yakalayabilmelidir. Doğru güç noktasının yakalanması, takibi yapan MPPT algoritmasının yeteneğine bağlıdır. Daha küçük olan güç noktasında takılı kalınması sistemin güç çıkışını düşürecektir.

¹ <https://ww2.mathworks.cn/help/physmod/sps/powersys/ref/pvarray.html> erişim tarihi 20.03.2019



Şekil 3.9. Matlab ile tek panelde gölgeleme benzetimi.




Şekil 3.10. FV dizindeki tek panelde gölgeleme.

FV sistemler şebekeye bağlı olup olmamalarına göre iki sınıfa ayrılırlar. Her sınıf kendi içinde farklı kurulum amaçlarına göre alt sınıflara ayrılabilir.

- Şebekeden bağımsız sistemler
 - DC sistemler
 - AC/DC sistemler
- Şebekeye bağlı sistemler
 - Merkezi güç santralleri
 - Dağıtık güç sistemleri

DC sistemler basit sistemler olup, bünyesinde az sayıda FV panel bulunduran sistemlerdir. Tarımsal sulama, su pompalama, aydınlatma gibi basit ihtiyaçlar için kullanılırlar. Panellerden elde edilen enerji DC akım ile çalışan yüke direkt olarak verilir ya da araya verimi artırmak için MPPT yetenekli bir DC-DC dönüştürücü eklenir. Bazı DC sistemlerde enerji depolamak amacıyla şarj kontrol cihazı ve batarya da kullanılmaktadır. Özellikle aydınlatma sistemlerinde, güneşin olduğu saatlerde bir şarj kontrol cihazı tarafından doldurulan batarya, gece olunca aydınlatma için ihtiyaç duyulan enerjiyi sağlamak amacıyla kullanılır. Şekil 3.11’de FV enerjiyle çalışan bir su pompalama sisteminin şeması görülmektedir.




Şekil 3.11. FV enerjiyle çalışan su pompalama sistemi (Gopal et al., 2013).

AC/DC sistemlerde DC yüklerin yanında AC yükleri de besleyebilmek için DC-AC eviriciler kullanılmaktadır. Günümüz eviricilerinin dönüşüm verimleri %90’lar seviyesindedir.

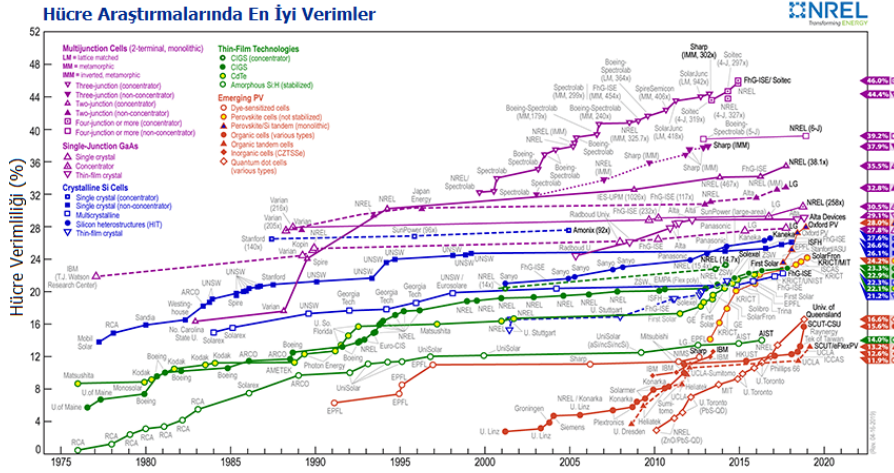
Şebekeye bağlı merkezi güç sistemleri ise, şebekenin tepe güç gereksinimine destek olmak amacıyla kurulmuş büyük ölçekli santrallerdir. Bununla birlikte evsel ihtiyaçları karşılamak amacıyla kurulmuş şebekeye bağlı sistemlerde vardır. Bu sistemler ise dağıtık güç sistemleri olarak adlandırılırlar. Çoğunlukla konutların çatılarına kurulurlar. Güçleri genellikle kWp seviyelerindedir. Bu sistemlerde üretilen enerji direkt olarak şebekeye aktarıldığı için sistemin batarya ihtiyacı yoktur. Bu nedenle ilk kurulum maliyetleri nispeten düşük sistemlerdir. Şebekeden bağımsız AC/DC sistemlerdeki eviriciler yerine şebekeye bağlı eviriciler kullanılır.

FV sistem teknolojileri alanındaki yoğun araştırma çalışmaları, bu sistemlerin kurulum maliyetlerini her geçen gün azaltmaktadır (Şekil 3.12). Bununla birlikte

yüksek verimler elde edilmeye de devam edilmektedir. Şekil 3.13'te görüldüğü gibi en yüksek verim, Fraunhofer Güneş Enerjisi Sistemleri Enstitüsünde üretilmiş deneysel çok-eklemlili hücre ile elde edilmiştir.



Şekil 3.12. Yıllara göre FV panel fiyatları ve toplam kurulu güç (Lafond et al., 2018).



Şekil 3.13. FV hücre teknolojileri araştırmalarında yıllara göre elde edilen verimler (NREL, 2019).

4. MAKİNE ÖĞRENMESİ

Makine öğrenmesi, bilgisayar bilimleri altında yer alan ve bir konu hakkında geçmiş verilerden deneyim elde ederek gerçeğe en yakın tahmini yapabilmekle ilgilenen bir alandır. Bu tahminleri yapabilmek için gereken algoritmaların tasarlanması ve geliştirilmesi süreçlerini barındırır. Makine öğrenmesinin ilgilendiği en temel problemler; sınıflandırma ve kümelemedir. Sınıflandırma, türü bilinmeyen bir örneği bilinen bir türe dâhil etme çalışmasıdır. Kümeleme ise benzer özellikler gösteren örneklerin aynı gruplara dâhil edilmesidir. Bu tez çalışmasında FV sistemlerdeki hataların tespiti amacıyla hataların sınıflandırılmasına dayalı, gözetimli öğrenme stratejisi kullanan bir topluluk öğrenmesi modeli kullanılmıştır. Gözetimli öğrenme, literatürde eğitmenli öğrenme, danışmanlı öğrenme ya da denetimli öğrenme gibi adlarla da anılmaktadır. Gözetimli öğrenme, giriş değişkenleri ve bunların hangi çıktıya karşılık geldiği bilgisinin bir arada öğrenildiği bir öğrenme stratejisidir. Bir başka deyişle giriş değişkenlerinin hangi çıkış değişkenine karşılık geldiği önceden bilinmektedir. Bu giriş ve çıkış değişkeni birlikteliğine etiketlenmiş veri de denilmektedir.

Makine öğrenmesi veya istatistiksel öğrenme alanında giriş ve çıkış değişkenleri farklı terimlerle de ifade edilmektedir. Örneğin çıkış değişkenleri; sonuç değişkeni, bağımlı değişken, hedef değişken, etiket, sınıf, hedef sınıf gibi terimlerle de ifade edilirken, giriş değişkenleri; bağımsız değişken, gözlemlenen değişken, kontrol değişkeni, özellik, öznelik, karakteristik gibi terimlerle ifade edilebilirler.

Eğer çıkış değişkeni sayısal değerlerden oluşuyorsa bu bir regresyon problemidir. Çıkış değişkeni kategorik (ayrık) değerlerden oluşuyorsa bu problem bir sınıflandırma problemidir. Örneğin, bir konutun fiyatının tahmin edilmesi problemi bir regresyon problemi, bir tümörün iyi huylu (0) ya da kötü huylu (1) olup olmadığının tahmin edilmesi problemi ise bir sınıflandırma problemidir. Bu problemlerin çözümünde problemin türüne göre regresyon algoritmaları ya da sınıflandırma algoritmaları kullanılmaktadır.

4.1. Terminoloji

Makine öğrenmesi alanında kullanılan pek çok terim birbirlerinin yerine kullanılabilir. Örneğin sınıflandırıcı terimi yerine bazen model ya da öğrenme algoritması terimleri kullanılabilir. Aşağıda bu terimler örneklerle kısaca açıklanmaya çalışılmıştır.

4.1.1. Veri seti

Belirli bir konu dâhilinde birbirleriyle ilişkili özelliklerin birleşiminden oluşan örneklerin oluşturduğu veri topluluğudur. Örneğin ABD Nüfus Sayımı Servisi tarafından toplanan bilgilerden elde edilmiş olan Boston konut fiyatları veri seti (Harrison and Rubinfeld, 1978) aslında küçük boyutlu bir veri seti olup 506 örnekten (gözlemden) oluşmaktadır. Veri setinde toplam 14 özellik (öznitelik) bulunmaktadır. Veri seti bir tabloya benzetilirse, örnekler bu tablonun 506 satırını, özellikler ise tablonun 14 sütununu oluşturur. Şekil 4.1’de Boston konut fiyatları veri setinden alınmış 5 adet örnek gösterilmiştir. Veri setindeki MEDV adlı özellik, konut fiyatlarının medyan değerlerinin 1000’e bölümünden elde edilmiştir. Veriler 1970 yılında yapılan nüfus sayımına aittir. Veri setinde konutun bulunduğu bölgedeki suç oranından (CRIM), öğrenci-öğretmen oranına (PTRATIO), konut başına ortalama oda sayısından (RM), Boston’daki 5 iş merkezine olan uzaklığın ağırlıklı ortalamasına (DIS) kadar değişik özellikler kısaltılmış özellik adlarıyla yer almaktadır. Makine öğrenmesi alanında ve özellikle regresyon problemlerinde çok sık kullanılan bu veri setindeki MEDV adlı özellik tahmin edilmeye çalışılan özellik olduğundan bu özelliğe hedef değişken adı da verilir.

	CRIM	ZN	INDUS	CHAS	NOX	RM	AGE	DIS	RAD	TAX	PTRATIO	B	LSTAT	MEDV
0	0.00632	18.0	2.31	0.0	0.538	6.575	65.2	4.0900	1.0	296.0	15.3	396.90	4.98	24.0
1	0.02731	0.0	7.07	0.0	0.469	6.421	78.9	4.9671	2.0	242.0	17.8	396.90	9.14	21.6
2	0.02729	0.0	7.07	0.0	0.469	7.185	61.1	4.9671	2.0	242.0	17.8	392.83	4.03	34.7
3	0.03237	0.0	2.18	0.0	0.458	6.998	45.8	6.0622	3.0	222.0	18.7	394.63	2.94	33.4
4	0.06905	0.0	2.18	0.0	0.458	7.147	54.2	6.0622	3.0	222.0	18.7	396.90	5.33	36.2

Şekil 4.1. Boston veri setinden örnekler.

Hedef değişkenler eğer kategorik değerlerden oluşuyorsa genellikle hedef sınıf olarak adlandırılırlar. Eğer hedef sınıfı {1, 0}, {doğru, yanlış}, {var, yok}, {iyi

huyulu, kötü huyulu} gibi sadece iki değerden oluşuyorsa bu tür sınıflandırma işlemi ikili sınıflandırma olarak adlandırılmaktadır. Fakat hedef sınıfı ikiden fazla kategorik değerden oluşuyorsa bu sınıflandırma işlemi çok-sınıflı sınıflandırmadır.

4.1.2. Hedef fonksiyon

Bir önceki bölümde verilen örnekten yola çıkarak, veri setindeki örnekler dâhilinde Boston'daki konut fiyatları modellenmek istenirse, bağımsız bir takım değişkenlere (özellikler) göre, bağımlı değişken olan konut fiyatını doğru olarak verebilecek fonksiyon, hedef fonksiyondur. Hedef fonksiyon $f(x) = y$ şeklinde gösterilirse, burada x bağımsız değişken, y bağımlı değişken, f ise hedef fonksiyondur. Sonuç olarak üretilen y değeri sayısal ya da ayrık değerli olabilir. Makine öğrenmesinin amacı hedef fonksiyona ulaşmak ya da ona en yakın fonksiyonu bulmaktır. Diğer bir deyişle hedef fonksiyonu modellemektir.

4.1.3. Hipotez

Gerçeğe en yakın tahminleri yapabilmek için hedef fonksiyonla aynı ya da ona çok yakın bir fonksiyon üretilmelidir. Hedef fonksiyona yaklaşılmaya çalışılan bu fonksiyona hipotez denir. Hipotez, bir konu hakkında bilgi sahibi olduktan sonra yapılan “eğitilmiş tahmin” olarak da ifade edilebilir. Hipotez fonksiyon $h(x) = y'$ şeklinde gösterilirse, burada x bağımsız değişken, y' tahmin, h ise hipotezdir.

4.1.4. Sınıflandırıcı

Sınıflandırıcı, türü bilinmeyen bir örneği belirli bir sınıfa dâhil etmek için kullanılan bir hipotez fonksiyondur. Tümör örneğinde sınıflandırıcı, tümörleri iyi ya da kötü huyulu ayrık değerler olarak etiketlemeye çalışan bir hipotezdir. Fakat hipotez ayrık değerli çıktılar üreten bir fonksiyon olduğu gibi konut fiyatlarını tahmin etmek için kullanılan bir fonksiyon da olabilir. Kısacası her sınıflandırıcı bir hipotezdir, fakat her hipotez sınıflandırıcı türünde olmayabilir.

4.1.5. Öğrenme algoritması

Öğrenme algoritması, veri setinden elde edilmiş eğitim verilerini kullanarak hedef fonksiyonu modellemeye çalışan bir talimatlar kümesidir. Makine öğrenmesi

araçları (yazılım, yazılım dili, yazılım kütüphanesi, vb.) ile hayata geçirilirler. Bu terim yerine sıklıkla “öğrenici” terimi de kullanılmaktadır. En sık kullanılan öğrenme algoritmalarından bazıları, doğrusal regresyon, lojistik regresyon, doğrusal ayrışma analizi, sınıflandırma ve regresyon ağaçları (Classification and Regression Trees – CART), naive bayes, k-en yakın komşular, destek vektör makineleri algoritmalarıdır.

4.1.6. Model

Model, öğrenme algoritmasının eğitim verilerinden öğrenmeye çalıştığı olgudur. Öğrenilen bilginin geçerliliği test edilerek, hipotezin kabul ya da reddedilmesi sağlanır. Makine öğrenmesi alanında model genellikle öğrenme algoritmasının eğitim verisi üzerinde çalıştırılmasıyla elde edilen yapı için kullanılır. Model, kendisine sunulan giriş verilerine karşılık çıktı (tahmin) üretir. Aynı öğrenme algoritması farklı eğitim verisi üzerinde çalıştırıldığında ya da farklı bir algoritma aynı eğitim verisi üzerinde çalıştırıldığında yeni bir model ortaya çıkar.

5. TOPLULUK ÖĞRENMESİ

Tek öğrenme algoritmasına dayanan karar verme süreçleri, kullanılan öğrenme modelinin kendi sınırlamalarından dolayı hatalı çıktılar üretebilir. Örneğin, bazı öğrenme modellerinin çıktısı, giriş değişkenlerinde yapılan küçük değişikliklerin ardından önemli ölçüde değişebilir. Bu kararsızlık problemi, FV sistemlerde hata tespiti gibi birçok değişkenin etkili olduğu saha uygulamaları için yanlış tahminlerle sonuçlanabilir.

Dietterich bir çalışmada, sınıflandırma, kümeleme ve regresyon problemlerinde, tek bir öğrenme algoritmasının kararlılığını ve tahminlerdeki doğruluğunu arttırmak için, topluluk öğrenmesi kavramını ortaya atmıştır (Dietterich, 2000). Topluluk öğrenmesi temelli bir model, bireysel olarak eğitilmiş aynı veya farklı türdeki modelleri bir araya getiren ve son bir tahmin üreten bir meta algoritmasıdır. Meta algoritması, örneklerin çıktılarını veri setinden değil, öğrenme algoritmalarının tahminlerinden öğrenen bir algoritmadır.

Topluluk öğrenmesi yöntemi, “Kalabalıkların Bilgeliği” gibi kavramlarla da adlandırılmıştır. Tarihte ilk kez Aristo’nun “Politika” adlı eserinde bahsettiği sosyolojik bir olgu olan kalabalıkların bilgeliği, en basit haliyle, ortak aklın, bireysel akıldan daha akıselim kararlar alabileceği şeklinde ifade edilebilir. Aristo’ya göre halkı oluşturan bireyler, tek başlarına bir konu hakkında yargıda bulunurken o işin uzmanından daha kötü kararlar alırlar. Fakat hep birlikte çalışırlarsa uzmanlardan daha iyi olacaklar ya da en azından daha kötü olmayacaklardır.

5.1. Topluluk Öğrenmesi Yöntemleri

Topluluk öğrenmesi yöntemlerini, oluşturulan modelin içerdiği temel öğrenme algoritmaların çeşitliliğine ve modelin oluşturulma şekline göre sınıflandırabiliriz.

5.1.1. Algoritma çeşitliliğine göre topluluk öğrenmesi yöntemleri

Topluluk öğrenmesi yöntemleri, modelin içerdiği öğrenme algoritmalarının çeşitliliğine göre iki sınıfa ayrılabilir:

- Heterojen topluluk
- Homojen topluluk

Heterojen topluluk modeli, aynı eğitim verisini farklı öğrenme algoritmalarına veya aynı algoritmalara farklı parametre ayarları ile uygular. Homojen topluluk modelinde ise, orijinal eğitim verileri farklı alt veri kümelerine bölünür ve aynı öğrenme algoritmasına alt veri kümesi adedince uygulanır (Wang et al., 2018). Böylece, heterojen topluluk modeli farklı öğrenme algoritmalarının birbirlerini tamamlamasını sağlayarak, homojen topluluk modeli ise temel olarak seçilen bir öğrenme algoritmasını, eğitim verilerinin farklı dağılımlarıyla eğiterek tahmin doğruluklarını arttırlar.

5.1.2. Oluşturma şekline göre topluluk öğrenmesi yöntemleri

Topluluk öğrenmesi yöntemleri, oluşturma şekillerine göre iki sınıfa ayırabilir:

- Ortalama yöntemleri
- Artırma yöntemleri

Ortalama yöntemlerinde, bağımsız olarak öğrenme modelleri oluşturulur ve bu temel modellerin ürettikleri tahminlerin ortalaması alınır. Ortalama yönteminde elde edilen birleşik tahmin genellikle temel modellerin tahminlerden daha iyidir. Bunun sebebi, ortalama alma işleminin varyansı da düşürmesidir. Bu yöntemlere örnek olarak, torbalama yöntemlerini, rasgele orman (Random Forest - RF) modelini, ekstra ağaçlar (Extra Trees - ET) modelini ve oylama (Voting - VT) yöntemini gösterebiliriz.

Torbalama yöntemlerinde orijinal eğitim verileri rastgele alt kümelere bölünür ve seçilen temel öğrenme algoritmasının örnekleri bu alt kümeler ile eğitilerek elde edilen tahminler birleştirilir ve son bir tahmin elde edilir. Bu yöntemler temel alınan algoritmanın sahip olduğu varyansı düşürmek için kullanılırlar. Böylece aşırı uyumlanma da düşürülmüş olur. Aşırı uyumlanmış bir model eğitim verilerindeki baskın trendi çözümlenmek ve öğrenmek yerine ezberlediği için eğitim verilerindeki tahmin doğruluğu yüksek çıkarken, daha önce

hiç görmediği yeni verilerle test edildiğinde ise çok daha düşük tahmin doğruluğu performansı gösterirler. Torbalama yöntemleri her öğrenme algoritmasıyla uygulanabilir. Bununla birlikte genellikle güçlü ve karmaşık algoritmalarda en iyi sonucu verir. Bu yöntemler de kendi aralarında örnek/ özellik alt kümelerinin oluşturulma şekline göre ayrılırlar. Breiman tarafından geliştirilen ve yöntem ailesine de ismini veren torbalama (Tree Bagging – TB) yönteminde temel öğrenme algoritması olarak CART kullanılmıştır. Çalışmada “*bootstrap*” adı verilen yöntemle orijinal veri setinden eşit boyutlarda örnek alt kümeleri iadeli çekilişler yaparak oluşturulur (Breiman, 1996). İadeli çekiliş yönteminde, orijinal veri setinden yeni bir alt küme oluşturulurken, rastgele çekiliş yapılır, ardından çekilen örnek, orijinal veri setine geri iade edilerek rastgele çekiliş yapma işlemine devam edilir. Böylelikle orijinal veri setindeki her örneğin çekilme olasılığı eşit olur. İadesiz çekiliş yönteminde ise alt küme oluşturulurken, yine rastgele çekiliş yapılır fakat çekilen örnekler orijinal veri setine geri iade edilmediğinden orijinal veri seti, çekilen örnek sayısı kadar azalır. Böylelikle her alt küme bir diğerinden tamamen farklı örnekler içerir.


Orijinal veri setinden örnek veri kümeleri oluşturulurken iadesiz çekiliş yönteminin kullanıldığı yöntem ise yapıştırma (Pasting – PS) yöntemi olarak adlandırılmıştır (Breiman et al., 1999). Bu çalışmayla, Breiman’ın 1996 yılında sunduğu torbalama yönteminin aksine, tüm veri setinin bellekte kalıcı olarak saklanma zorunluluğu ortadan kalkmış ve büyük ölçekli veri setleriyle çalışılırken artan bellek kullanımı ihtiyacı azaltılmaya çalışılmıştır.

Alt kümeler oluşturulurken, orijinal veri setindeki örnekler yerine özelliklerden rastgele alt kümelerin oluşturulduğu yöntem ise rastgele alt uzay (Random Subspace - RS) yöntemidir (Ho, 1998). Ho, önerdiği yöntem ile farklı özellikler içeren alt kümeler kullanarak, öncelikle temel algoritmalar arasındaki farklılığı arttırmak istemiştir. Bu çalışmada da düşük bellek kullanımı ayrıca hedeflenmiştir.

Orijinal veri setinden hem örnekler, hem de özelliklerden rastgele seçimlerle alt kümeler oluşturuluyorsa bu yöntem rastgele parça (Random Patch – RP) yöntemi olarak anılır (Louppe and Geurts, 2012). Araştırmacılar, bu yöntemin diğer

torbalama yöntemlerine göre önemli ölçüde düşük bellek kullanımı ve işlem süresi ile daha iyi ya da eşit tahmin doğruluğu da sunduğunu belirtmişlerdir.

Rastgele orman modeli ise torbalama yönteminin özelleşmiş bir şeklidir. Torbalama yönteminden en önemli farkı temel öğrenme algoritması olarak sadece karar ağacı kullanmasıdır. Rastgele orman modeli oluşturulurken, önceden belirtilen sayıda karar ağacının her biri, orijinal veri setinden iadeli çekilişle oluşturulmuş örnek alt kümeleri üzerinde büyütülür (Şekil 5.1).



Şekil 5.1. Rastgele orman modelinin yapısı.

Ek olarak, karar ağaçları büyütülürken her bir düğümün bölünmesi sırasında, rastgele seçilen bir özellik alt kümesindeki en ayırt edici eşik değeri seçilir (Breiman, 2001). Özellik alt kümesinin rastgele seçilmesi sonucu orman modelinin önyargısı genellikle bir miktar artsa da, tüm karar ağaçlarının tahmin ortalaması

alındığından, modelin varyansı daha fazla oranda azalır. Oysaki standart bir karar ağacı algoritması, düğümlerin bölünmesi işlemlerinde, bir özellik alt kümesinden değil tüm özellikler içerisinde en ayırt edici eşik değerini veren özelliği seçer. Karar ağaçları, bir düğümü bölerek alt düğümleri oluştururken aslında alt düğümlerde daha homojen verilerin olmasını hedefler. Bunun için farklı yöntemler kullanılır. Hangi tür yöntemlerin kullanılacağını ise hedef sınıf/değişkenin tipi belirler. Problemden tahmin edilmesi gereken hedef sınıf/değişken kategorik değerlerden oluşuyorsa entropi, gini, sınıflandırma hatası yöntemleri, sayısal değerlerden oluşuyorsa en küçük kareler yöntemi kullanılır.

Ekstra ağaçlar modelini rastgele orman modelinden ayıran iki önemli fark vardır. Bunlardan ilki, karar ağaçlarını büyütürken bootstrap yöntemi ile oluşturulmuş örnek alt veri kümeleri yerine tüm orijinal veri setini kullanmasıdır. Buradaki amaç önyargıyı minimize etmektir. İkinci fark ise, düğümlerin bölünmesi sırasında rastgele seçilen özellik alt kümesindeki en ayırt edici eşik değerini seçmek yerine hedef sınıftan tamamen bağımsız rastgele bir özellik seçmektir (Geurts et al., 2006). Böylelikle rastgele orman modelindeki rastlantısallık bir adım daha ileriye taşınmış olur. Bunun sonucu olarak genellikle modelin varyansı bir miktar daha düşer. Araştırmacılar, önerdikleri modelin rastgele orman modelinden daha hızlı ve özellikle çok büyük veri setlerinde gürültü içeren verilere karşı daha dayanıklı olduğunu belirtmişlerdir.

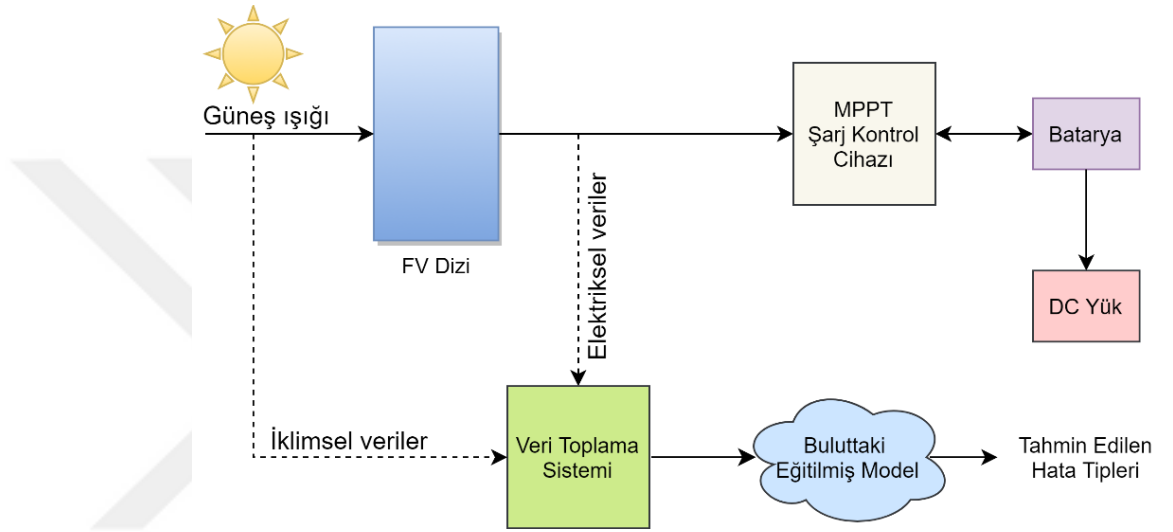
Rastgele orman ve ekstra ağaçlar modellerinde son tahminin nasıl elde edileceği çözülmeye çalışılan probleme göre belirlenir. Eğer problem bir sınıflandırma problemi ise tüm karar ağaçlarından elde edilen tahminlerde oy çoğunluğuna bakılırken, problem regresyon problemi ise tahmin olasılıklarının ortalaması alınır.

Oylama yönteminde ise orijinal veri seti üzerinde çalıştırılan farklı tipteki öğrenme algoritmalarından elde edilen tahminler birleştirilerek son bir tahmin elde edilir. Son tahmin elde edilirken, oy çokluğuna bakılır ya da tahmin olasılıklarının ortalaması alınır. Oylama yöntemi genellikle birbirine yakın performans gösteren farklı öğrenme algoritmalarının bireysel zayıflıklarını dengelemek amacıyla kullanılır.

Arttırma yöntemlerinde ise ilk olarak temel bir öğrenme algoritması seçilir. Seçilen bu algoritma, başlangıçta her biri eşit ağırlıktaki örneklerden oluşan bir örnek alt kümesi üzerinde çalıştırılır ve elde edilen model, örnekleri sınıflandırmak için tahminde bulunur. Algoritma, bir önceki sınıflandırma işleminde yanlış sınıflandırılan örneklerin ağırlık değerleri arttırılarak güncellenmiş eğitim veri setinden, yeniden çekilerek oluşturulan örnek alt kümesi üzerinde tekrar çalıştırılır. Ağırlıkları arttırılan örneklerin bir sonraki adımda örnek alt kümesine seçilme ihtimali doğru sınıflandırılan örneklere göre daha fazla olmaktadır. Bu şekilde aynı temel algoritma tekrar tekrar çalıştırılır. Böylelikle nispeten zayıf bir algoritma sıralı bir şekilde dizilerek daha düşük önyargıya sahip bir model elde edilir. Burada zayıf bir algoritmadan kasıt, rastgele tahmin yapmaktan biraz daha iyi olan bir algoritmadır. Son tahmin, algoritmaların sınıflar için yaptıkları ağırlıklı tahminlerin ortalaması alınarak oluşturulur. Bu yöntemlere örnek olarak, Uyarlamalı Arttırma (Adaptive Boosting – AdaBoost), Gradyan Arttırma Makineleri (Gradient Boosting Machines – GBM), Aşırı Gradyan Arttırma (Extreme Gradient Boosting – XGBoost) modellerini gösterebiliriz.

6. GEREÇ VE YÖNTEM

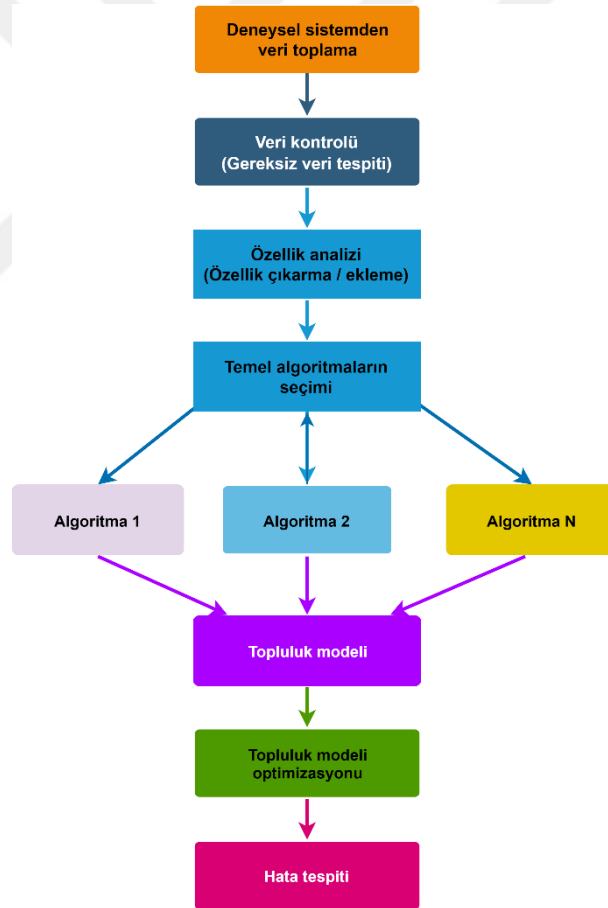
Bu tez çalışmasında FV sistemler için bulut bağlantılı bir izleme sistemi tasarlanması ve izlenen verilerin yine gönderileceği bulut ortamında özgün olarak geliştirilmiş topluluk öğrenmesi temelli bir model ile analiz edilerek hızlı ve doğru bir hata tespitinin yapılabilmesi amaçlanmıştır. Şekil 6.1, tez çalışması kapsamında gerçekleştirilen bulut bağlantılı izleme sistemini temsil etmektedir.



Şekil 6.1. Bulut bağlantılı FV izleme sistemi şematik gösterimi.

Şekil 6.2’de yapılan çalışmanın adımları gösterilmiştir. Çalışma kapsamında Muğla ilindeki bir konut üzerinde deneysel bir FV güç sistemi kurulmuştur. Kurulan deneysel sistemden, geliştirilen bir izleme sistemi aracılığıyla toplanan elektriksel ve iklimsel veriler düzenli olarak kaydedilmiştir. Tez çalışmasında, takip edilen FV güç sisteminde meydana gelebilecek olası hataların tespitini yapmak amacıyla geleneksel hata tespit sistemlerinden farklı olarak topluluk öğrenmesi temelli özgün bir hata tespit sistemi önerilmiştir. Önerilen hata tespit sistemi, topluluk öğrenmesi temelli modelin FV sistemlerdeki hataları sınıflandırmak amacıyla kullanılmasına dayanmaktadır. Deneysel sistemden elde edilen veriler, sınıflandırma problemlerinde yaygın olarak kullanılan bazı aday öğrenme algoritmalarının eğitilmesi ve test edilmesi için kullanılmıştır. Bu çalışmada aday algoritmalar olarak, güçlü bir artırma yöntemi olan Gradyan Artırma (Gradient Boosting - GB), hedef sınıfları arasındaki en iyi ayırım yapan eksenleri arayan İkinci

Dereceden Ayrımcı Analiz (Quadratic Discriminant Analysis - QDA), Basit Karar Ağacı (Decision Tree - DT), Rastgele Orman (Random Forest - RF), Ekstra Ağaçlar (Extra Trees - ET) ve sınıflandırma problemlerinde yaygın olarak kullanılan istatistiksel bir yöntem olan Lojistik Regresyon (Logistic Regression - LR) algoritmaları seçilmiştir. Aday algoritmaların tahmin doğruluklarını arttırmak amacıyla parametre optimizasyonu yapılmış ve algoritmaların parametreleri iyileştirilmiştir. Bu algoritmalardan ikili, üçlü ve dördü seçenekler şeklinde topluluk modelleri oluşturulmuştur. Topluluk modelleri oluşturulurken oylama yöntemi tercih edilmiştir. Oluşturulan tüm topluluk modelleri, çok katlı çapraz doğrulama ile tahmin doğrulukları açısından test edilmiştir. En başarılı modeller bulunduğundan sonra bu modeller üzerinde parametre optimizasyonu ile iyileştirme yapıp yapılamayacağı araştırılmış ve ardından son modele karar verilmiştir.




Şekil 6.2. FV izleme sistemi hata tespit adımları.

Yapılan çalışmanın detayları takip eden bölümlerde detaylı olarak ele alınacaktır.

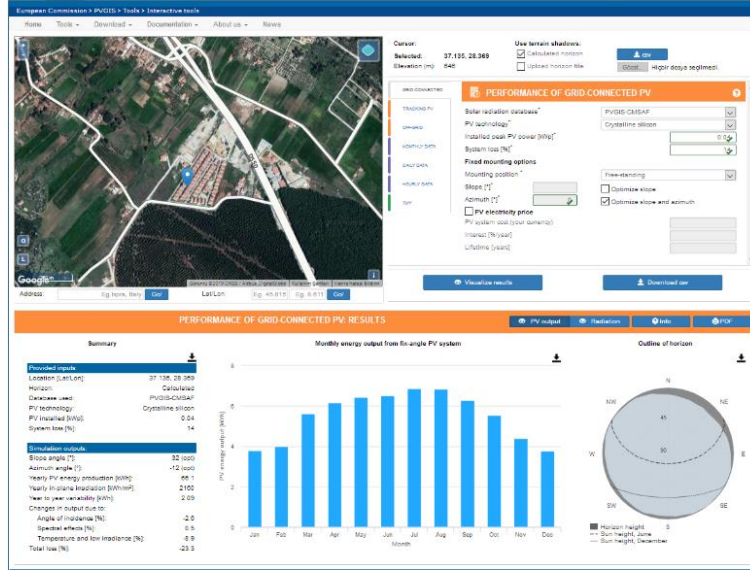
6.1. Deneysel Sistem

Bu tez çalışmasında Şekil 6.3'te gösterilen deneysel güç sistemi tasarlanmış ve Muğla ilindeki bir konut üzerinde kurulmuştur. Şekilde görüldüğü gibi deneysel sistem; 4 adet güneş paneli, MPPT özellikli şarj kontrol cihazı, DC yük ve bataryadan oluşmaktadır. Deneysel sistem bu haliyle şebekeden bağımsız DC bir sistemdir. Çalışmada izleme sistemindeki tüm bileşenlerin beslenmesi elektriksel yükü oluşturmaktadır. Bulut bağlantılı izleme sisteminin ihtiyacı olan güç, batarya çıkışına bağlanan bir DC-DC dönüştürücü ile elde edilmiştir. DC-DC dönüştürücü, batarya çıkışını 12V'dan 9V'a indirmekte ve bu çıkış değeri başka bir DC-DC dönüştürücü ile bulut bağlantılı izleme sisteminde yer alan bileşenlerin ihtiyacı olan 3,3V ve 5V sabit değerlerine çevrilmektedir.



Şekil 6.3. Deneysel güç sistemi.

Deneysel sistemdeki FV paneller sabit bir şekilde kurulmuştur. Eğer bir FV sistem güneşi takip edebilme yeteneğine sahip değilse, sahip olduğu paneller tüm yıl boyunca güneşten en fazla yararlanabileceği en uygun eğim ve azimut açılarıyla konumlandırılmalıdırlar. Bu nedenle deneysel sistemin kurulu olduğu bölgeye en uygun eğim ve azimut açıları, Fotovoltaik Coğrafi Bilgi Sistemi (Photovoltaic Geographical Information System - PVGIS) web sitesinden (JRC PVGIS, 2017) edinilmiştir (Şekil 6.4). PVGIS web sitesinde deneysel sistemin benzetimini yapabilmek için gerçek kurulum konumu haritadan seçilmiştir. Kurulum bölgesi için önerilen eğim açısı 32° , azimut açısı ise -12° 'dir. Çalışmada kullanılan panellerin teknik özellikleri Çizelge 6.1'de verilmiştir. Paneller 2 seri x 2 paralel olacak şekilde bağlanmıştır.



Şekil 6.4. PVGIS'e göre en uygun eğim ve azimut açıları.

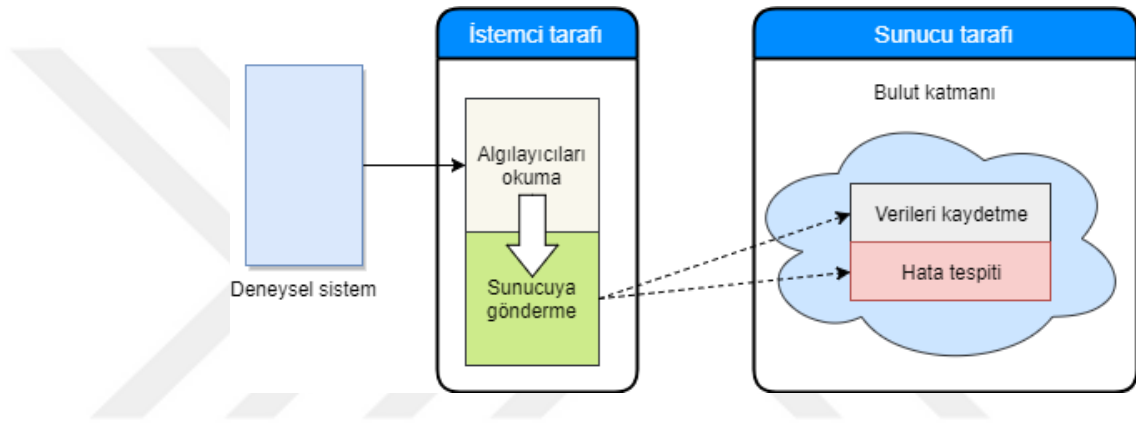
Çizelge 6.1. Topray Tps105S mono-kristal FV panel teknik özellikleri.

Özellik	Açıklama
Model	TOPRAY TPS105S Mono-kristal
MPP gücü (P_{mp})	10W
Açık devre gerilimi (V_{oc})	21,0V
MPP gerilimi (V_{mp})	16,8V
Kısa devre akımı (I_{sc})	0,66A
MPP akımı (I_{mp})	0,59A
Akım-sıcaklık katsayısı	$6,60e^{-4}A/^{\circ}C$
Gerilim sıcaklık katsayısı	$-0,0798V/^{\circ}C$
Hücre sayısı	36

FV paneller tarafından üretilen enerjinin depolanabilmesi ve deneysel sistemdeki DC yüklerin çalıştırılabilmesi için bir adet 12V-14Ah akü, batarya olarak kullanılmıştır. Panellerden gelen enerjiyi toplayarak bataryayı şarj edebilmek için teknik özellikleri EK I'de verilen MPPT özellikli bir şarj kontrol cihazı kullanılmıştır. MPPT özellikli şarj kontrol cihazları, farklı ışınım seviyeleri ve hücre sıcaklıklarında dahi panellerden toplanan enerjiyi en yüksek seviyede tutmaya çalışırlar. Bunu yaparken panellerin ürettiği akım ve gerilim değerlerini sürekli takip eden ve en yüksek güç noktasını bulmaya çalışan algoritmalar kullanırlar.

6.2. Bulut Bağlantılı İzleme Sistemi

Deneysel sistemden elektriksel ve iklimsel verilerin toplanması ve kaydedilmesi için tez çalışması kapsamında bulut bağlantılı bir izleme sistemi geliştirilmiştir. Bulut bağlantılı izleme sistemi istemci-sunucu mimarisine uygun olarak geliştirilmiştir. İzleme sisteminde, deneysel sistemden verileri toplayan taraf istemci tarafıdır. İstemci tarafı, toplanan verileri sunucu tarafına göndermektedir (Şekil 6.5). Sunucu tarafı ise bulut katmanında çalışan, verileri veri tabanına kaydetme ve hata tespiti yapma görevlerini yerine getiren iki ayrı yazılımdan oluşmaktadır.




Şekil 6.5. FV izleme sistemi istemci-sunucu yapısı.

6.2.1. İstemci tarafı

İstemci tarafı, elektriksel ve iklimsel verileri anlık ölçen algılayıcılar ve ATmega2560 mikro-denetleyici ile ESP8266 WIFI yongası da içeren Arduino¹ Mega tabanlı geliştirme kartından oluşmaktadır. Elektriksel ve iklimsel veriler, izlenen panel dizisinin elektriksel çıkışı ile FV paneller düzlemine düşen güneş ışınımı, panellerin arka yüzey sıcaklıkları, ortamdaki hava sıcaklığı ve nem miktarıdır. İstemci tarafını yöneten geliştirme kartı, resmi Arduino Mega geliştirme kartı üzerine ESP8266 WIFI yongası eklenerek, kablosuz ağlara (internet/intranet) bağlanma yeteneği kazandırılmış bir karttır. Şekil 6.6'da gösterilen kart iki ana birimden oluşmaktadır. Bunlardan ilki ATmega2560 mikro-denetleyici tarafından yönetilen Mega birimi, diğeri ise 32-bit Tensilica L106 işlemci barındıran Espressif

¹ <https://www.arduino.cc/> erişim tarihi 7 Aralık 2017.

ESP8266EX mikro-denetleyici tarafından yönetilen ve kablosuz ağlara bağlanmayı sağlayan Esp birimidir. ESP8266EX yaygın olarak algılayıcı ağları ve nesnelerin interneti (Internet of Things - IoT) uygulamalarında kullanılmaktadır. Her iki birimin birlikteliği, izleme sisteminin istemci tarafını oluşturmaktadır.



Şekil 6.6. Arduino uyumlu Mega+WiFi geliştirme kartı.

Çizelge 6.2. Mega+WiFi kartı çalışma şekilleri.

No.	Seçenek	8'li anahtar grubu							
		1	2	3	4	5	6	7	8
1	USB-Esp (Yazılım yükleme)	0	0	0	0	1	1	1	0
2	USB-Esp (Dinleme)	0	0	0	0	1	1	0	0
3	USB-Mega (Yazılım yükleme / dinleme)	0	0	1	1	0	0	0	0
4	USB-Mega-Esp (Yazılım yükleme)	1	1	1	1	0	0	0	0
5	Mega-Esp (Yazılım yükleme / dinleme)	1	1	0	0	0	0	0	0
6	Tüm bölümler bağımsız	0	0	0	0	0	0	0	0

Her iki birimde yer alan mikro-denetleyiciler ayrı amaçlarla programlanabilmektedir. Programlama işlemi, ilgili birimdeki belleğe, mikro-denetleyicinin çalıştıracağı yazılımın yüklenmesiyle olmaktadır. Kartın çalışma şekli, Şekil 6.6'da kırmızı çerçeve içine alınmış alanda görülen 8'li anahtar grubu ile Çizelge 6.2'de görülen seçenekler arasından seçilebilmektedir. Karttaki herhangi bir birime yazılım yüklenmesi 8'li anahtar grup ayarlanarak ve kart bir USB kablosu aracılığıyla PC'ye bağlanarak sağlanır. PC ile USB arasındaki haberleşme işlemi CH340 USB-seri port dönüştürücü yonga aracılığıyla

yapılmaktadır. Bununla birlikte her iki birimin birbirleriyle haberleşmesi de seri port 3 üzerinden mümkündür.

Bu tez çalışmasında geliştirme kartının Mega ve Esp birimleri için ayrı yazılımlar geliştirilmiştir. Mega birimi, deneysel sistemde yer alan tüm algılayıcıları yönetmek, algılayıcılardan verileri toplayarak paket haline getirmek, bu veri paketini bellek kartına kaydetmek ve seri port 3 üzerinden Esp birimine göndermek için programlanmıştır. Esp birimi ise Mega biriminden kendisine gelen veri paketini, sunucu tarafını oluşturan iki ayrı yazılımdan birine göndermek için programlanmıştır.

6.2.1.1. Mega birimi

Mega biriminin programlanması için 8'li anahtar grubu (Bkz. Şekil 6.6), geliştirme kartı USB üzerinden PC'ye bağlı değilken, 3 numaralı çalıştırma seçeneğinde (Bkz. Çizelge 6.2) gösterildiği şekilde ayarlanır. Ardından kart USB kablosu ile PC'ye bağlanarak Mega birimi için geliştirilen yazılım yüklenir. Bu yazılım geliştirilirken kullanılan platform aslında, açık kaynak kodlu Processing dili üzerine inşa edilmiş ve C++ programlama dili ile geliştirilmiş kütüphaneleri kullanarak mikro-denetleyici programlamayı kolaylaştıran Wiring¹ platformunu temel alır. Bu programlama dili ve geliştirme platformu Arduino projesini doğurmuştur. Arduino projesi, temel olarak Processing ara yüzünü kullanan ve C++ programlama dilinin basitleştirilmiş bir çeşidini barındıran haliyle, mikro-denetleyici programlamayı kolaylaştırmak amacıyla ortaya çıkmıştır.

Mega birimi yazılımının kontrol ettiği algılayıcılar, paneller düzlemine düşen güneş ışınımını ölçen bir piranometre, panellerin arka yüzey sıcaklıklarını ölçen sıcaklık algılayıcıları, ortamdaki hava sıcaklığını ve nemini ölçen bütünleşik algılayıcı ve izlenen panel dizisinin ürettiği akım ve gerilim değerlerini ölçen algılayıcılardır. Mega birimi yazılımı, tüm algılayıcıları ve bellek kartını kontrol edebilmek için bu donanımlara ait yazılım kütüphanelerini kullanmaktadır.

¹ [https://en.wikipedia.org/wiki/Wiring_\(development_platform\)](https://en.wikipedia.org/wiki/Wiring_(development_platform)) erişim tarihi 25 Haziran 2016.

FV panellerin çıkış karakteristikleri, doğrusal olmayan yapıdadır ve önemli ölçüde ışınım seviyesi ile panel sıcaklığına bağlıdır. Bu nedenle bu iki parametre, FV modelleme çalışmalarında ve FV izleme sistemlerinde yaygın olarak takip edilen parametrelerdendir. Paneller düzlemine düşen güneş ışınımını ölçmek için kullanılan Apogee firmasının ürettiği PRY-S model piranometre Şekil 6.7’de gösterilmiştir. Piranometreye ait teknik özellikler EK I’te verilmiştir.



Şekil 6.7. Apogee, PYR-S model piranometre.

Kullanılan piranometre kendinden beslemeli olup tam gün ışığında, $1100W/m^2$ ışınım değeri altında $220mV$ çıkış gerilimi üretmektedir. Bu değer her $5W/m^2$ ışınım değeri için $1mV$ çıkış gerilimi anlamına gelmektedir. Bu mV seviyesindeki çıkış gerilimi, Mega geliştirme kartının her biri 10-bit çözünürlüğe sahip olan 16 analog girişinden birisine uygulanmıştır. Mikro-denetleyicinin varsayılan ayarlarla algılayabileceği gerilim aralığı $0 - 5V$ aralığındadır. Bu ayarlarla algılanabilecek en düşük gerilim değeri ise $5V/2^{10} = 4,88mV$ olarak hesaplanabilir. Bu değerler, analog girişler üzerinden algılanabilecek en düşük ışınım değerinin $4,88mV * 5Wm^{-2}/1mV = 24.4W/m^2$ olduğunu gösterir. Bu hassasiyeti arttırmak amacıyla, Arduino geliştirme kartlarının analog girişleri için izin verilen gerilim aralığını değiştirebilme özelliği kullanılmıştır. Bu amaçla Mega geliştirme kartının analog girişlerinin gerilim aralığı $0 - 1,1V$ olarak ayarlanmıştır. Böylelikle mikro-denetleyicinin, analog girişlerde algılayabileceği en düşük gerilim seviyesi $1,1V/2^{10} = 1,07mV$, en düşük ışınım seviyesi ise $1,07mV * 5Wm^{-2}/1mV = 5,35W/m^2$ olarak değiştirilmiştir. Bu değişikliğin ardından piranometrenin çıkış gerilimi mikro-denetleyicinin seçilen analog girişine uygulanmıştır. Kullanılan analog giriş $2ms$ 'lik aralıklarla 100 kez okunmuş ve okunan değerlerin ortalaması alınmıştır. Böylelikle analog girişlerde meydana

gelebilecek elektriksel gürültünün de azaltılması hedeflenmiştir. Elde edilen analog giriş değeri ortalaması aşağıdaki eşitlikte kullanılarak güneş ışınımı değeri hesaplanmıştır.


$$Işınım = 1,07mV * \left(\frac{\text{Analog giriş değeri ortalaması}}{1mV/5Wm^{-2}} \right) \quad (6.1)$$

FV panellerin çıkış gücünü etkileyen bir diğer önemli faktör ise panelleri oluşturan güneş hücrelerinin çalışma sıcaklıklarıdır. Hücre sıcaklığı, ölçülmesi daha kolay olan panel arka yüzey sıcaklığı bilgisi kullanılarak aşağıdaki eşitlik ile tahmin edilebilir (King et al., 2004).

$$T_c = T_m + \frac{G}{G_{ref}} \Delta T \quad (6.2)$$


Bu eşitlikte, T_c hücre sıcaklığı ($^{\circ}C$), T_m panel arka yüzey sıcaklığı ($^{\circ}C$), G panel yüzeyine düşen ışınım miktarı (W/m^2), G_{ref} referans ışınım miktarı ($1000W/m^2$), ΔT ise malzemeye göre değişen sıcaklık farkı katsayısıdır. ΔT değerinin, cam-hücre-cam şeklinde lamine edilmiş panel için $2^{\circ}C$, cam-hücre-polimer tabaka için ise $3^{\circ}C$ olduğu varsayılabilir (King et al., 2004).

Tez çalışmasında, güneş panellerinin arka yüzey sıcaklıklarını ölçmek için kullanılan Maxim firmasının ürettiği DS18B20 model sıcaklık algılayıcı Şekil 6.8’da görülmektedir.



Şekil 6.8. Maxim, DS18B20 sıcaklık algılayıcısı.


Bu algılayıcılar panellerin arka kısmına, arada ısı geçirgenliğini arttıran termal macun olacak şekilde sabitlenmiştir. Her panel için toplam 4 adet algılayıcı kullanılmıştır (Şekil 6.9). Panel arka yüzey sıcaklığı T_m , bu 4 adet algılayıcıdan elde edilen sıcaklık değerlerinin ortalamasıdır. Ortalama alma işlemi Mega birimi yazılımında sıcaklık algılayıcıları okunduktan sonra gerçekleştirilir.



Şekil 6.9. Panel arkasındaki sıcaklık algılayıcıları.

DS18B20 sıcaklık algılayıcısı -10°C ile $+85^{\circ}\text{C}$ aralığında $\pm 0,5^{\circ}\text{C}$ doğruluk derecesiyle sıcaklık ölçümü yapabilmektedir. Bunun yanında -55°C ile $+125^{\circ}\text{C}$ aralığı normal ölçüm aralığıdır. Her bir algılayıcı, 64-bitlik eşsiz bir kimlik numarasına sahiptir. Bu kimlik numarası ile çok sayıda algılayıcı tek-hatlı seri haberleşme protokolü kullanarak tek bir veri hattı üzerinden 200m uzaklığa kadar veri gönderebilmektedir.

Şekil 6.10'da DS18B20 ile geliştirme kartı arasındaki bağlantı şeması görülmektedir. Bağlantı $4,7\text{K}\Omega$ 'luk direnç ile yükseğe çekilmiştir. Algılayıcı veri hassasiyeti 9-bit ile 12-bit aralığında çözünürlüğe sahip olabilir. Tüm algılayıcılar 9-bit çözünürlüğe sahip olacak şekilde ayarlanmıştır. Algılayıcılar, seçilen çözünürlükte $0,5^{\circ}\text{C}$ doğrulukla ölçüm yapabilmektedir. Çözünürlük ayarlaması Mega birimine yüklenen yazılımda kullanılan algılayıcı kütüphanesinin TEMPERATURE_PRECISION tanımlı değişkeni ile yapılmaktadır.




Şekil 6.10. Sıcaklık algılayıcısı bağlantı şeması.

Çizelge 6.3. DS18B20 sıcaklık algılayıcısı çözünürlük seçenekleri.

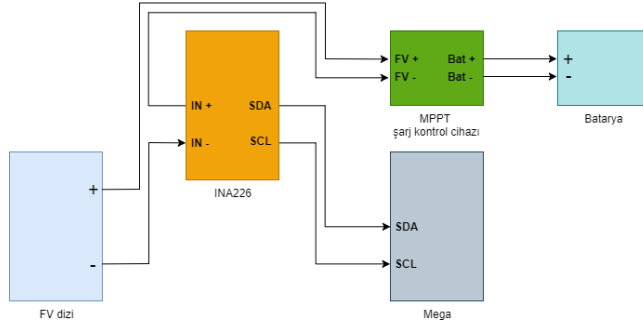
Çözünürlük	Doğruluk	Çevrim süresi
9-bit	0,5°C	93.75ms
10-bit	0,25°C	187,5ms
11-bit	0,125°C	375ms
12-bit	0,0625°C	750ms

Panel dizisinin ürettiği akım ve gerilim değerlerini ölçmek için kullanılan Texas Instruments firmasının ürettiği INA226 algılayıcısı Şekil 6.11’de gösterilmiştir. INA226 algılayıcısı I²C (Inter-Integrated Circuit) eşzamanlı haberleşme protokolü üzerinden veri alışverişi yapan, çift yönlü akım ve güç izleme algılayıcısıdır. Algılayıcı 36V’a kadar gerilim, 10A’e kadar akım ölçebilmekle birlikte gerilim bölücü devre ve yüksek güçlü ve düşük değerli şönt direnç kullanımı ile bu değerler arttırılabilmektedir. Arduino ile SDA (Serial Data) ve SCL (Serial Clock) hatları üzerinden haberleşir. SDA hattı, çift yönlü veri iletişim hattıdır. SCL hattı ise SDA hattına bağlı tüm cihazları kontrol eden yönetici cihazın ürettiği saat sinyalini taşır.




Şekil 6.11. Texas Instruments, INA226 akım, gerilim algılayıcısı.

Şekil 6.12’de INA226 ile geliştirme kartı arasındaki bağlantı şeması görülmektedir. I²C protokolü, yönetici cihazın SDA ve SCL hattı üzerine çok sayıda farklı uç cihaz bağlantısı imkânı vermektedir. Genellikle kısa mesafeli ve düşük aktarım hızlı veri alışverişinde tercih edilmektedir.



Şekil 6.12. INA226 algılayıcısı bağlantı şeması.

Deneysel sistemin çalıştığı ortamdaki hava sıcaklığı ve bağıl nem miktarını ölçmek için kullanılan Adafruit firmasının ürettiği DHT22 algılayıcısı Şekil 6.13’de gösterilmiştir. DHT22 algılayıcısı nem ölçümünde %0 - %100 aralığında en fazla %2 - %5 doğruluk ile ölçüm yapabilirken, sıcaklık ölçümünde -40°C - 80°C aralığında $\pm 0,5^{\circ}\text{C}$ doğruluk derecesinde ölçüm yapabilmektedir. En düşük ölçüm zaman aralığı 2s’dir. Algılayıcı, ölçüm esnasında en fazla 2,5mA akım çekmektedir.



Şekil 6.13. Adafruit, DHT22 sıcaklık ve bağıl nem algılayıcısı.

Mega birimi tarafından algılayıcılardan toplanan veriler, yerel depolama seçeneği olarak Micro SDHC bellek kartı üzerinde metin dosyası olarak depolanabilirler. Bu tip bellek kartını kullanabilmek için Şekil 6.14’te gösterilen kart adaptörü kullanılmıştır.



Şekil 6.14. Micro SDHC bellek kartı adaptörü.

Bellek kartı içinde yıl-ay-gün formatında isimlendirilmiş metin dosyasında sırasıyla:

- FV dizi numarası ($I_{d_{str}}$),
- FV dizinin ürettiği gerilim (V_{str}),
- FV dizinin ürettiği akım (I_{str}),
- FV dizinin ürettiği güç (P_{str}),
- Mega biriminin piranometre bağlı analog girişinden okunan değer (A_{in}),
- Hesaplanan ışınlım değeri (G),
- Ortam sıcaklığı (T_a),
- Ortamdaki nem miktarı (Hum),
- Panel arkasındaki algılayıcı-1'den okunan sıcaklık (T_1),
- Panel arkasındaki algılayıcı-2'den okunan sıcaklık (T_2),
- Panel arkasındaki algılayıcı-3'den okunan sıcaklık (T_3),
- Panel arkasındaki algılayıcı-4'den okunan sıcaklık (T_4),
- Dört algılayıcının ortalaması (T_m) değerleri kaydedilmektedir.

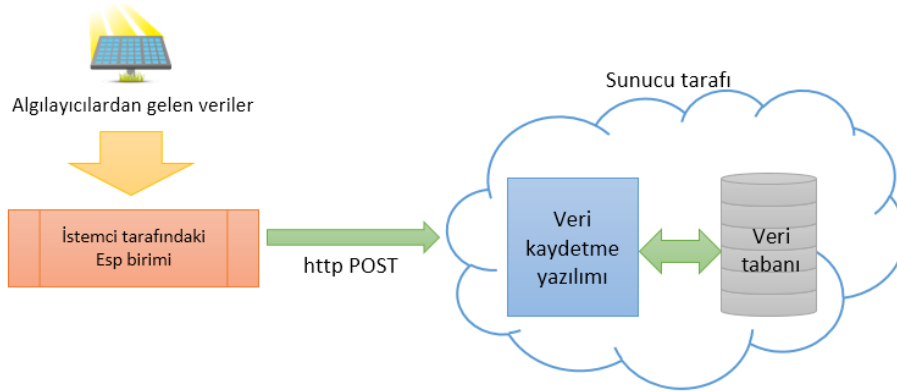
Hücre sıcaklığı (T_c) ise panel arka yüzey sıcaklıkları ortalaması (T_m) değeri kullanılarak hesaplanır (Bkz. Eşitlik 6.2). Hesaplama işlemi, sunucu tarafında hata tespiti aşamasından hemen önce ya da sunucuya göndermeden istemci tarafında yapılabilir.

Mega birimi tarafından toplanan tüm veriler, bellek kartında depolandıktan sonra paket haline getirilir. Paket haline getirilen verinin başına verinin kullanılma amacına göre özel bir karakter eklenir ve seri port 3 üzerinden Esp birimine gönderilir. Eklenen bu karakterin tipine göre Esp birimi paketi sunucu tarafındaki verileri kaydetme ya da hata tespiti yapma yazılımlarından birine gönderir.

6.2.1.2. Esp birimi

İstemci tarafında yer alan Esp birimi, kendisine gönderilen veri paketinin sunucu tarafına gönderilmesinden sorumludur. Bunun için, çekim alanı içerisindeki, kablosuz alan ağı adı (Service Set Identifier - SSID) ve erişim şifresi bilinen bir kablosuz internet ağına bağlanmalıdır. Kablosuz ağa bağlanmak için gerekli erişim bilgileri Esp birimine yüklenen yazılımda belirtilir. Kablosuz ağa bağlanan Esp birimi, Mega tarafının kendine veri paketi gönderip göndermediğini anlamak için sürekli olarak seri portu dinler. Eğer seri porta gelen bir veri paketi varsa, paket sonunda yer alan satır sonu işareti (\r) gelene kadar dinleyerek gelen veri paketini geçici olarak kaydeder. Kaydedilen veri paketi, paket başındaki özel karakterin tipine göre veri saklama ya da hata tespiti yapma amacıyla sunucu tarafına gönderilir. Bu gönderim işlemi, POST türünde gerçekleşen bir http isteğidir. Sunucu tarafındaki web servisi ise, kendisine gelen bu isteğin başarılı bir şekilde yerine getirilip getirilmediğini belirten bir cevabı, isteği gönderen istemciye – ki bu uygulamada istemci tarafındaki Esp birimi kastedilmektedir – geri gönderir.

Esp birimi sunucu tarafına sadece verileri saklama amacıyla istekte bulunsa da, sunucu tarafında veri saklama işlemi haricinde verilerde değiştirme ya da verileri silme işlemleri de yapılabilmektedir. Fakat verileri değiştirme ve silme işlemleri Esp birimi haricindeki başka istemciler tarafından yapılabilmektedir. Esp birimine verileri değiştirme ve silme yetkisi verilmemiştir. Bu birim sadece verileri kaydetmesi için sunucuya göndermekle yükümlüdür. Şekil 6.15'te Esp birimi ve sunucu tarafı arasındaki haberleşme şekli görülmektedir.



Şekil 6.15. Esp birimi ve sunucu tarafı arasındaki haberleşme.


```

Command Prompt
Microsoft Windows [Version 10.0.17134.590]
(c) 2018 Microsoft Corporation. All rights reserved.

C:\Users\Ceyhun>curl -XGET https://pv-system-monitor.herokuapp.com/api/strdat/1/1/last10
{"Error":false,"Message":"Success","Strdat":[{"recordno":2329,"pvs_id":1,"strarr_id":1,"vmp":29.017,"imp":-1.22,"pmp":35.858,"irradiation":12.96,"analog_in":2.41,"amb_temp":30.2,"humidity":41.3,"cell_temp0":31,"cell_temp1":31,"cell_temp2":32,"cell_temp3":31.5,"cell_temp_avg":31.38,"created":"2018-09-23T18:12:21.000Z"},{"recordno":2328,"pvs_id":1,"strarr_id":1,"vmp":22.726,"imp":19.348,"pmp":439.459,"irradiation":7.58,"analog_in":1.41,"amb_temp":30.3,"humidity":40.2,"cell_temp0":31,"cell_temp1":31,"cell_temp2":32,"cell_temp3":32,"cell_temp_avg":31.5,"created":"2018-09-23T18:11:51.000Z"},{"recordno":2327,"pvs_id":1,"strarr_id":1,"vmp":23.148,"imp":19.501,"pmp":450.903,"irradiation":9.84,"analog_in":1.83,"amb_temp":30.4,"humidity":40,"cell_temp0":31.5,"cell_temp1":32,"cell_temp2":32.5,"cell_temp3":32,"cell_temp_avg":32,"created":"2018-09-23T18:11:20.000Z"},{"recordno":2326,"pvs_id":1,"strarr_id":1,"vmp":17.42,"imp":20.63,"pmp":359.349,"irradiation":7.37,"analog_in":1.37,"amb_temp":30.6,"humidity":39.4,"cell_temp0":31.5,"cell_temp1":31.5,"cell_temp2":32.5,"cell_temp3":32,"cell_temp_avg":31.88,"created":"2018-09-23T18:10:53.000Z"},{"recordno":2325,"pvs_id":1,"strarr_id":1,"vmp":29.857,"imp":14.343,"pmp":428.777,"irradiation":10.91,"analog_in":2.03,"amb_temp":30.7,"humidity":39,"cell_temp0":32,"cell_temp1":32,"cell_temp2":33,"cell_temp3":32.5,"cell_temp_avg":32.5,"created":"2018-09-23T18:10:17.000Z"},{"recordno":2324,"pvs_id":1,"strarr_id":1,"vmp":28.848,"imp":16.082,"pmp":463.873,"irradiation":12.74,"analog_in":2.37,"amb_temp":30.8,"humidity":38.3,"cell_temp0":32,"cell_temp1":32,"cell_temp2":33.5,"cell_temp3":33,"cell_temp_avg":32.63,"created":"2018-09-23T18:09:48.000Z"},{"recordno":2323,"pvs_id":1,"strarr_id":1,"vmp":29.26,"imp":15.808,"pmp":463.11,"irradiation":11.4,"analog_in":2.12,"amb_temp":31,"humidity":38.2,"cell_temp0":32.5,"cell_temp1":32.5,"cell_temp2":33.5,"cell_temp3":33,"cell_temp_avg":32.88,"created":"2018-09-23T18:09:17.000Z"},{"recordno":2322,"pvs_id":1,"strarr_id":1,"vmp":16.99,"imp":22.033,"pmp":374.608,"irradiation":16.24,"analog_in":3.02,"amb_temp":31.1,"humidity":38.7,"cell_temp0":32.5,"cell_temp1":32.5,"cell_temp2":34,"cell_temp3":33.5,"cell_temp_avg":33.13,"created":"2018-09-23T18:08:45.000Z"},{"recordno":2321,"pvs_id":1,"strarr_id":1,"vmp":25.243,"imp":20.202,"pmp":510.413,"irradiation":18.87,"analog_in":3.51,"amb_temp":31.1,"humidity":39.2,"cell_temp0":33,"cell_temp1":33,"cell_temp2":34,"cell_temp3":34,"cell_temp_avg":33.5,"created":"2018-09-23T18:08:14.000Z"},{"recordno":2320,"pvs_id":1,"strarr_id":1,"vmp":23.923,"imp":21.179,"pmp":506.598,"irradiation":30.54,"analog_in":5.68,"amb_temp":31,"humidity":38,"cell_temp0":33,"cell_temp1":33,"cell_temp2":34.5,"cell_temp3":34,"cell_temp_avg":33.63,"created":"2018-09-23T18:07:41.000Z"}]}
C:\Users\Ceyhun>

```

Şekil 6.17. Komut satırından curl aracı ile yapılmış http isteği

Curl komutları kullanılarak sunucu tarafından veri çekmek haricinde verileri değiştirme ya da silme işlemleri de yapılabilir. Bunun için sunucu tarafındaki web servisi yazılımında PUT ve DELETE fiillerini kullanabilen fonksiyonların kodlanmış olması yeterlidir.

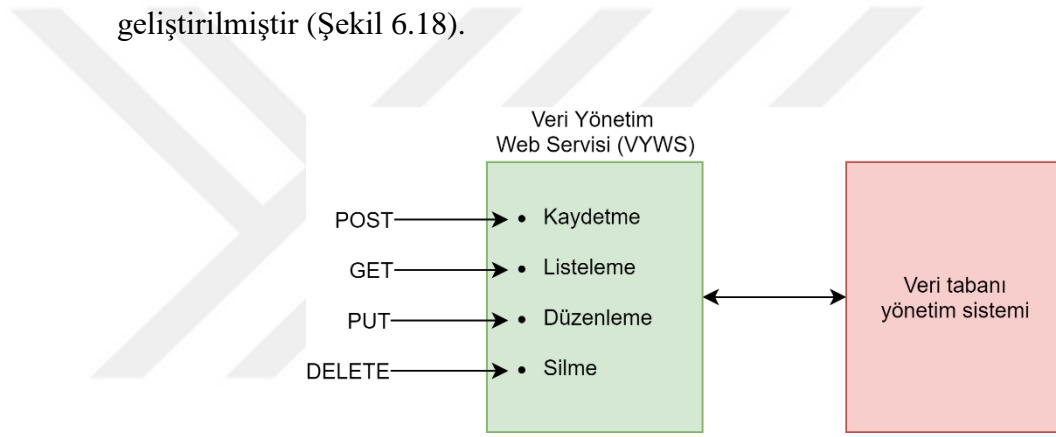
6.2.2. Sunucu tarafı

Bulut bağlantılı izleme sisteminin sunucu tarafı iki adet yazılımdan oluşmaktadır. Her iki yazılım da REST¹ mimarisinde geliştirilmiş RESTful servislerdir. REST mimarisinde geliştirildikleri için uygulama programlama arayüzünü (Application Programming Interface – API) kullanan her türlü istemciden veri alma ve gönderme işlemleri yapılabilmesi mümkündür. Yazılımlardan ilki, istemci tarafından gönderilen http isteğine göre gönderilen veri paketini kabul ederek bu çalışma kapsamında tasarlanan veri tabanına kaydeden, veri tabanında kayıtlı verileri değiştiren ya da silen bir web servisedir. Bu web servisini kısaca Veri Yönetim Web Servisi (VYWS) olarak adlandırabiliriz. Tüm veriler özel tasarlanan bir veri tabanında tutulmaktadır. Veri tabanı yönetim sistemi olarak MySQL² kullanılmaktadır. Verilerin kaydedildiği veri tabanı yönetim sistemleri, onları kullanan uygulamalardan uzakta olabilirler. Özellikle gömülü sistemler, veri tabanı yönetim sistemlerini kendi üzerlerinde çalıştırmak için yeterli

¹ <https://tr.wikipedia.org/wiki/REST> erişim tarihi 5 Aralık 2016.

² <https://www.mysql.com/> erişim tarihi 1 Mart 2019.

sistem kaynağına sahip değildir. Gömülü sistemlerde kullanılacak, dosya tabanlı çalışabilen SQLite¹ gibi hafif veri tabanları olsa da bunlar çok fazla veri saklayabilecek kapasiteye sahip değildir. Bu durumda istemciler, uzak noktadaki, hâlihazırda çalışan bir veri tabanına internet üzerinden erişmek zorundadırlar. Veri tabanı yönetim sistemleri, özellikle gömülü sistem istemcilerin doğrudan veri tabanına yazma ve okuma izinleriyle erişmelerine izin vermemektedir. Bu kısıtlamanın en önemli iki nedeni; oluşabilecek bir güvenlik açığı ihtimalini ortadan kaldırmak ve veri tabanına erişmek isteyen her istemci türü için ayrı bir API geliştirme zorunluluğundan kurtulmaktır. Bu nedenle sunucu tarafındaki VYWS, veri tabanı yönetim sistemine erişebilen, böylelikle verileri listelemek için okuyan, kaydeden, düzenleyen, silen bir web servisi olarak geliştirilmiştir (Şekil 6.18).



Şekil 6.18. Veri yönetim web servisinin (VYWS) çalışma şekli.

Sunucu tarafının ikinci yazılımı ise bu tez kapsamında geliştirilen hata tespit sistemine herhangi bir istemci tarafından ulaşılabilmemesine izin veren web servisi. Bu web servisini de kısaca Hata Tespit Web Servisi (HTWS) olarak adlandırabiliriz. Bu çalışma kapsamında geliştirilen her iki web servisi de istemciler tarafından kendilerine gönderilen http isteklerine karşı geriye bir cevap gönderir. Bu cevaplar JavaScript nesne gösterimi (JavaScript Object Notation - JSON²) formatında olacak şekilde tasarlanmıştır. JSON formatı düşük veri boyutu ve kolay anlaşılır yapısı ile RESTful web servislerde en sık kullanılan metin tabanlı cevap formatlarından biridir. Diğer yaygın formatlar genişletilebilir işaretleme dili

¹ <https://sqlite.org/> erişim tarihi 21 Mart 2017.

² <https://tr.wikipedia.org/wiki/JSON> erişim tarihi 5 Aralık 2016.

(eXtensible Markup Language – XML), virgülle ayrılmış veriler (Comma Separated Value – CSV) gibi yine metin tabanlı formatlardır.

VYWS geliştirilirken açık kaynak kodlu Node.js¹ JavaScript platformu kullanılmıştır. Node.js, Google'a ait, C++ ile geliştirilmiş açık kaynak kodlu V8 JavaScript Motoru² temel alınarak geliştirilmiş, sunucu tarafında çalışabilen ağ uygulamaları geliştirmek için kullanılan bir JavaScript platformudur. İşlemci olarak x64, IA-32, ARM ya da MIPS üzerinde koşturan pek çok işletim sisteminde çalışabilmektedir. Node.js uygulamaları JavaScript dili kullanılarak geliştirilirler. Node.js, kullandığı npm³ paket yöneticisi ile, geliştiricinin, uygulamaya yeni kod kütüphaneleri ekleyebilmesini sağlar. Npm paket yöneticisi ayrı bir uygulama olarak kurulabileceği gibi Node.js kurulumuna da eklenebilir. Npm, milyonlarca tekrar kullanılabilir kod paketini barındıran, bu paketlerin paylaşılabilirdiği, dağıtılabildiği ve geliştirici platformlara kolaylıkla eklenebildiği bir ekosistemdir.

VYWS, içerdiği Express⁴ web uygulama çatısı yardımıyla bir RESTful web servisi olarak çalışabilmektedir. Express, Node.js özelliklerini kullanmaya izin veren esnek bir ara-katman yazılımıdır. Bünyesinde istemci ve sunucu arasındaki http isteği ve http cevabı nesnelere yönetilmesini sağlayan yazılım fonksiyonları barındırmaktadır. Böylelikle istemciden gelen farklı http isteklerine karşılık, farklı http cevaplarının üretilmesi mümkün olmaktadır. Bu çalışma kapsamında geliştirilen VYWS, istemci tarafından (Esp birimi ya da herhangi bir web tarayıcı) gelen http isteğine göre izleme verilerinin kaydedilmesi, listelenmesi, düzenlenmesi ya da silinmesi gibi işlemleri yerine getirerek istemci tarafına bir http cevabı gönderir.

HTWS geliştirilirken ise, Python programlama dili ve Scikit-learn⁵ makine öğrenmesi kütüphanesi kullanılmıştır. Scikit-learn makine öğrenmesi kütüphanesi,

¹ <https://nodejs.org/en/about/> erişim tarihi 21 Mart 2017.


² <https://v8.dev/> erişim tarihi 1 Mart 2019.

³ <https://www.npmjs.com/> erişim tarihi 21 Mart 2017.


⁴ <https://expressjs.com/> erişim tarihi 1 Mart 2019.

⁵ <https://scikit-learn.org/stable/> erişim tarihi 2 Şubat 2018.

sınıflandırma, regresyon ve kümeleme problemlerinde, öğrenme modellerinin seçilmesi, optimizasyonu ve performanslarının test edilmesinde, veri setlerindeki özelliklerin seçilmesinde, verilerin normalleştirilmesinde ve verilerin görselleştirilmesinde yaygın olarak kullanılmaktadır. Tüm bu işlevleri içerdiği fonksiyon sınıfları ile tek bir çatı altına topladığı için veri analizi ve makine öğrenmesinde en çok tercih edilen platformlardan biridir (Şekil 6.19 ve Şekil 6.20).



Şekil 6.19. Veri biliminde Python-R-Matlab kullanımı (“Data science trends,” 2019).



Şekil 6.20. Makine öğrenmesinde Python-R-Matlab kullanımı (“Machine learning trends,” 2019).

HTWS ise web uygulama çatısı olarak Flask¹ kullanmaktadır. Flask da tıpkı Express gibi istemci ve sunucu arasındaki http isteği ve cevabı döngüsünü kontrol edebilen fonksiyonlar içeren bir ara katman yazılımıdır. Python destekli

¹ <http://flask.pocoo.org/> erişim tarihi 1 Mart 2019.

platformlarda çalışabilmektedir. Bu çalışmada Flask, istemciden gelen http isteklerini (FV sistemin çalışma durumunun tahmin edilmesi) karşılayıp yapılan tahminleri JSON formatında http cevabı olarak istemciye geri gönderme görevini yerine getirmektedir.

Bu çalışmada geliştirilen her iki web servisini barındıracak sunucu platformu olarak Heroku¹ platformu tercih edilmiştir. Heroku, bütünleşik veri tabanı yönetim sistemleri barındırmakta ve çok dilli geliştirmeye olanak sağlamaktadır. Platform hizmeti (Platform As A Service - PaaS) türünde bir bulut bilişim hizmetidir. Platform kavramı burada bilgisayarın mimarisini, işletim sistemini, bu işletim sistemine kurulmuş yazılım geliştirme ortamlarını ve ara yüzlerini kapsamaktadır. PaaS, bu platformların, bütün bir servis olarak geliştiricilerin hizmetine sunulmasıdır. Heroku, Node.js yanında, Ruby, Java, Php, Python, Go, Scala ve Closure dilleriyle de uygulama geliştirmeye izin vermektedir.

Her iki web servisi de ilk önce PC üzerinde geliştirilmiş ve ardından Heroku komut satırı aracı kullanılarak Heroku sistemine yüklenmiştir. Web servislerinin kullandığı farklı yazılım kütüphaneleri varsa, bunlar proje klasörlerinde yer alan ayar dosyaları içerisinde belirtilirler. Bu yazılım kütüphaneleri, Heroku tarafından sunucuya yüklenerek projenin eksik bir yazılım kütüphanesinden dolayı çalışmaması olasılığının önüne geçilmiş olur. Projelerin sunucu tarafında çalıştırılması sırasında ortaya çıkacak olan herhangi bir yazılım hatası ve hataya neden olan yazılım kod satırı sunucu tarafında tutulan arşiv kayıtlarında kaydedilmektedir. Böylelikle geliştiricinin hataları bulup gidermesi kolaylaşmaktadır. Heroku platformu, işlemci ve bellek gücü gibi sistem kaynaklarının yetmediği durumlarda, geliştiricilere ölçeklenebilir ücretlerle ek sistem kaynakları sunmaktadır.

6.3. Hata Tespit Sistemi

Bu tez çalışması kapsamında geliştirilen hata tespit sistemi, takip edilen FV güç sisteminde meydana gelebilecek hataları tespit etmek amacıyla geleneksel hata

¹ <https://www.heroku.com/> erişim tarihi 21 Mart 2017.

tespit sistemlerinden farklı olarak topluluk öğrenmesi temelli bir model kullanmaktadır. Hata tespit sistemi, topluluk öğrenmesi temelli modelin FV sistemlerdeki hataları sınıflandırmak amacıyla kullanılmasına dayanmaktadır. Sistem FV dizi seviyesinde çalışmaktadır. Geliştirilen hata tespit sistemi ilk olarak PC’de tasarlanmış ve ardından sunucu tarafında çalışabilir hale getirilmiştir. Bu çalışmada geliştirilen Esp birimi, FV diziden Mega biriminin topladığı izleme verilerini hata tespiti yapılması amacıyla HTWS sistemine göndermektedir. Bu gönderim işlemi POST türünde bir http isteğidir. HTWS sistemi, gelen izleme verilerini kullanarak bir hata tespiti yapar ve geriye bir cevap gönderir. Gönderilen cevapta izlenen sistemde eğer varsa hatanın türü için bir tahmin ve öngörülen olasılığı bilgileri bulunmaktır. Hata tahminini yapan topluluk öğrenmesi modelinin oluşturulması devam eden bölümlerde detaylı olarak ele alınacaktır.

6.3.1. Hata tespit sisteminin oluşturulması

Hata tespit sisteminin temelini oluşturan topluluk öğrenmesi modeli sunucu tarafında çalıştırılmadan önce çevrimdışı çalışacak şekilde tasarlanmış ve test edilmiştir. Bunun için Python ve R dilleri ile yazılım geliştirme eko-sistemlerinden biri olan Anaconda¹ dağıtımı tercih edilmiştir. Anaconda dağıtımı veri madenciliği ve makine öğrenmesi alanlarında çok sık kullanılan ve farklı işletim sistemlerinde çalışabilen ücretsiz bir dağıtımdır. Topluluk öğrenmesi modelinin çevrimdışı geliştirilmesi ve test edilmesinin yanında, sunucu tarafında çalıştırılması için kullanılan tüm yardımcı kütüphaneler Çizelge 6.4’te listelenmiştir.

Çizelge 6.4. Topluluk öğrenmesi modelinde kullanılan kütüphaneler.

Kullanım amacı	Kullanılan kütüphane
Makine öğrenmesi	scikit-learn
Veri yapıları ve analizi	pandas ²
Veri matrisi işlemleri	NumPy ³

¹ <https://www.anaconda.com/> erişim tarihi 1 Mart 2019.

² <http://pandas.pydata.org/> erişim tarihi 1 Mart 2019.

³ <http://numpy.org/> erişim tarihi 1 Mart 2019.

Veri görselleştirme	Matplotlib ¹ , Seaborn ²
Web uygulaması	Flask

6.3.2. Özellik seçimi


Makine öğrenmesinde doğru öğrenme modelinin seçimi kadar eğitim veri setinin tutarlı olması da önemlidir. Bir öğrenme modelinin performansı, eğitim verilerindeki faydalı bilgileri alabilmesine ve böylelikle bu verilerdeki baskın trendi öğrenmesine bağlıdır. Öğrenme algoritması eğer eğitim verilerini kullanarak hedef fonksiyona çok yakın modelleme yapıyorsa bu model aşırı uyumlanmış bir model olabilir. Bu durum, gerçek hayatta bir konuyu gerçekten öğrenmek yerine ezberlemeye benzemektedir. Aşırı uyumlanmış bir model önceden eğitimini aldığı verileri, tekrar tahmin etmeye kalktığında yüksek bir başarıyla tahmin edebilir. Bu, o modelin eğitim skorudur. Fakat aşırı uyumlanmış model, daha önce hiç görmediği veriler karşısında başarılı tahminler yapamayacaktır. Çünkü model genelleme yapamamakta, sahip olduğu bilgiyi yeni şartlara adapte ederek kullanamamaktadır. Sonuç olarak aşırı uyumlanmış bir modelin test skoru, eğitim skoruna göre kayda değer şekilde düşük olacaktır. Aşırı uyumlanma problemi, fazla gürültü içeren veri setlerinde modelin özellikler arasındaki ilişkiden çok verideki gürültüyü tanımlamaya çalıştığı durumlarda da ortaya çıkabilen bir problemdir.

Aşırı uyumlanmanın tersi olan düşük uyumlanmış bir model ise öğrenme algoritmasının hedef fonksiyonu modellerken başarısız olması anlamına gelmektedir. Eğitim verilerindeki faydalı bilgiyi alamadığı için hem eğitim verilerinde hem de daha önce hiç görmediği veriler karşısında başarısız olacaktır. Düşük uyumlanmış bir modelin rastgele tahmin yapmaktan bir farkı yoktur. Bu nedenle hem eğitim skoru hem de test skoru düşüktür. Aşırı ya da düşük uyumlanmış bir model başarısız bir model olacağından bu iki durumun önüne geçmek gereklidir. Bunun için öncelikle veri setindeki faydalı bilgilerin ön plana çıkarıldığı, faydasız bilgilerin ise elendiği bir yaklaşım izlenebilir. Böylelikle

¹ <http://matplotlib.org/> erişim tarihi 1 Mart 2019.

² <http://seaborn.pydata.org/> erişim tarihi 1 Mart 2019.

öğrenme modeli, eğitim verilerinde, kendini yanıltan ya da yanlış bilgilendiren örneklerle karşılaşmayacaktır. Şekil 6.21'de temsili bir modelin farklı uyumlanmasına örnekler gösterilmektedir.



Şekil 6.21. Öğrenme modellerindeki uyumlanma çeşitleri örneği.

Bazı veri setlerinde ise özellik sayısı, örnek sayısıyla orantısız şekilde çok fazla olabilir. Bu veri setlerinde, veri örneklerinin belirli bölgelerde kümelendiği durumlarda bu kümelenme bölgeleri boyut olarak ifade edilirse, boyut sayısı arttıkça, boyut başına düşen örnek sayısı da azalacaktır. Boyutluluk laneti (Curse of Dimensionality) olarak adlandırılan bu problem, giderek artan veri boyutlarıyla uğraşmak zorunda kalan makine öğrenmesi, veri madenciliği ve biyoinformatik alanlarının ortak problemidir. Bazı öğrenme algoritmaları bu çok boyutlu, boyut başına az örnek içeren veri setleri üzerinde çalıştırıldığında ortaya başarılı bir model çıkaramazlar. Bu nedenle bu tarz veri setlerinde boyutsal küçülmeye gidilmelidir. Çok fazla özellik barındıran veri setlerinde faydalı bilginin çoğunu kaybetmeden özellik sayısının azaltılması anlamına gelen boyutsal küçülme tekniklerinin kullanılması, veri setinin öğrenme modeli için daha kolay anlaşılabilir hale getirilmesi ve başarının artmasıyla sonuçlanacaktır. Fakat boyutsal küçülme işlemi hatalı yapılırsa veri setinde faydalı bilgiler içeren özellikler kaybolabilir ve öğrenme modelinin performansı düşebilir.

Boyutsal küçülme için veri setinden konuyla alakasız ve gereksiz özelliklerin elenmesi ile bazı durumlarda var olan özelliklerden yeni özellikler türetilmesi de gerekebilir. Örneğin bir eğitim verisinde hedef sınıfın tahmini için anlam ifade etmeyen metin türünde veri içeren bir özelliğin sayısal veriye dönüştürülmesi bir özellik türetilmesi örneğidir.

Özellik seçimi için aşağıdaki yöntemler kullanılabilir:

- Varyans eşiği: Eğitim veri setinde örnekler arasında çok fazla değişim göstermeyen diğer bir deyişle varyansı belirli bir eşik değerinin altında kalan özelliklerin elenmesi yöntemidir.
- Korelasyon eşiği: Birbirleriyle benzer oranlarda değişim gösteren diğer bir deyişle birbirleriyle yüksek korelasyona sahip özelliklerin elenmesi yöntemidir. Bu özellikler gereksiz özellikler olarak kabul edilir.
- Genetik algoritmalar: Evrimsel biyoloji ve doğal seçilimden ilham alan genetik algoritmaların kullanılarak en uygun özelliklerin aranması yöntemidir.
- Kademeli arama: Sıfırdan başlayıp her adımda bir özellik ekleyerek özellik sayısının artırıldığı ya da tam tersi tüm özelliklerle başlayıp her adımda bir özelliğin eksiltildiği ve hemen ardından modelin başarısının test edildiği sıralı arama yöntemidir. Özellik artırma şeklinde uygulanan yöntemde performanstaki iyileşme durana kadar devam edilirken, özellik eksiltme şeklinde uygulanan yöntemde ise performans birden büyük ölçüde düşene kadar devam edilir.
- Tek değişkenli istatistiksel test: Özellik seçiminin tek değişkenli istatistiksel testlere dayanarak yapılması yöntemidir. Yanlış tahmin oranı (False Discovery Rate – FDR), yanlış pozitif oranı (False Positive Rate – FPR), ki-kare testi gibi yöntemler kullanılabilir.

Tez çalışması kapsamında özellik seçimi için Scikit-learn makine öğrenmesi kütüphanesinde özellik seçimi paketinde tanımlı bir fonksiyon olan *chi2* kullanılmıştır. Bu fonksiyon özellik skorlarını tayin etme amacıyla ki-kare testinden faydalanmaktadır.

Çizelge 6.5. Ki-kare testiyle belirlenmiş özellik skorları.

Özellik adı	Skoru
P_{str}	114848,42
I_{str}	2997,70
G	1179,90
V_{str}	246,57
T_c	166,53

T_4	133,06
T_2	132,88
T_3	128,93
T_m	128,31
T_1	118,90
T_a	21,30
Hum	18,96

Çizelge 6.5'te gösterildiği gibi FV panel arka yüzey sıcaklıkları T_1, T_2, T_3, T_4 ile bunların ortalaması olan T_m özellikleri birbirlerine yakın skorlara sahiptirler. Eşitlik 6.2 kullanılarak elde edilmiş olan T_c özelliği ise diğer tüm panel sıcaklığıyla ilgili özelliklerden daha yüksek skor elde etmiştir. Bu özelliğin T_m özelliği kullanılarak türetilmesi işlemi HTWS yazılım kodunda yapılmaktadır.

Çizelge 6.5 incelendiğinde ortam sıcaklığı (T_a) ve nem (Hum) özelliklerinin diğerlerine kıyasla daha düşük skor elde ettikleri anlaşılmaktadır. Her ne kadar ortam sıcaklığı bir FV güç sistemi için önemli bir iklim verisi olsa da, sahip olunan veri setindeki örnekler özelinde aldığı skordan dolayı bağıl nem özelliği ile veri setinden çıkarılmış ve öğrenme modellerinin oluşturulmasında kullanılmamıştır. Özellik seçiminin ardından kullanılacak tüm özellikler sırasıyla $V_{str}, I_{str}, P_{str}, G, T_c$ olarak belirlenmiştir.

Özellik seçiminin ardından, eğitim veri setindeki her örnek, gözetimli öğrenmenin doğası gereği, izlenen FV dizinin normal ve hatalı koşullarda çalıştığını ifade eden "Case" etiketli hedef sınıfı altında sınıflandırılmıştır. Sınıflandırılan tüm hata tipleri Çizelge 6.6'da listelenmiştir.

Çizelge 6.6. Hata tiplerinin sınıflandırılması.

Case #	Hata koşulu
Case 0	Normal çalışma.
Case 1	Dizideki bir panelin gölgelenmesi.
Case 2	Dizideki iki panelin gölgelenmesi.
Case 3	Dizideki bir panelde kısa devre olması.

Bu hata sınıfları, FV sistemden veri toplanırken, bir hata kontrollü olarak gerçekleştirildiğinde ilgili hata tipine ait etiketin, toplanan veriye manuel olarak eklenmesi şeklinde kaydedilmektedir. Böylelikle gözetimli öğrenmenin gerektirdiği etiketlenmiş veri seti oluşturulmaktadır.

FV dizideki panellerin gölgelenmesi ve kısa devre hataları Şekil 6.22 ve Şekil 6.23'te görüldüğü gibi canlandırılarak hata senaryoları oluşturulmuş ve bu durumlarda ölçümlere devam edilerek FV sistemin elektriksel çıktıları ilgili hedef sınıf etiketiyle eşleştirilerek kaydedilmiştir. Tek ve çift panel üzerindeki gölgelenme senaryoları için Şekil 6.22'de görülen yarı saydam malzemeler kullanılarak FV panel üzerine düşen güneş ışınımı miktarının belirli bir seviyede azalması sağlanmıştır. FV paneller için kısa devre hata senaryosu ise Şekil 6.23'te görüldüğü gibi FV panel geçiş (by-pass) diyotunun bir iletken kablo aracılığıyla kısa devre edilmesi şeklinde gerçekleştirilmiştir.


Şekil 6.24'te bu çalışmada tespit edilen hata tipleri için hata senaryolarının nasıl gerçekleştirildiği şematik olarak gösterilmiştir. Şekil 6.24.(a) hatasız çalışma senaryosunun, Şekil 6.24.(b) tek paneldeki gölgelenme senaryosunun, Şekil 6.24.(c) iki paneldeki gölgelenme senaryosunun, Şekil 6.24.(d) ise tek paneldeki kısa devre senaryosunun nasıl gerçekleştirildiğini göstermektedir.



Şekil 6.22. Bir paneldeki gölgelenme senaryosu.



Şekil 6.23. Bir paneldeki kısa devre senaryosu.




Şekil 6.24. Hata senaryoları gerçekleştirme şeması (a) Normal çalışma, (b) Tek panelin gölgelenmesi, (c) İki panelin gölgelenmesi, (d) Tek panelin kısa devre olması.

Algılayıcılar tarafından 30 saniyelik aralıklarla ölçülen veriler, bellek kartına depolanmış ve internet erişiminin mümkün olduğu durumlarda da Esp birimi tarafından sunucu tarafına gönderilmiştir. Sunucu tarafında gönderilen bu veriler hata tespiti için geliştirilen topluluk öğrenmesi temelli modelin ve bu modeli oluşturan aday öğrenme algoritmalarının eğitilmesinde ve test edilmesinde kullanılmıştır. Elde edilen etiketlenmiş veri setinde, gerçekleştirilen hata senaryolarının FV dizinin güç üretimini ne kadar etkilediği de incelenmiştir. Birbirlerine yakın güneş ışınımı şartlarında değerlendirilmesi için art arda gerçekleştirilen hata senaryoları ölçümlerinde FV dizideki tek bir panelin gölgelendiği durumlarda normal çalışmaya göre yaklaşık %35'lik bir ortalama güç kaybı olmuştur. FV dizideki iki panelin gölgelendiği durumlarda ise ortalama güç kaybı yaklaşık %46'lara çıkmıştır. FV dizideki tek bir panelin kısa devre olduğu durumlarda da ortalama güç kaybı yaklaşık %48 olarak tespit edilmiştir. Hızlı ve doğru bir hata tespiti, yüksek güç kayıplarının en kısa sürede önlenmesi açısından büyük önem taşımaktadır.

6.3.3. Öğrenme algoritmalarının optimizasyonu

Tez çalışması kapsamında kullanılan aday algoritmalar GB, QDA, DT, RF, ET ve LR algoritmalarıdır. Bu algoritmaların hangi parametrelerle daha başarılı tahmin yapabileceğini anlamak için algoritmalar test edilmelidir. Makine öğrenmesi alanında, kullanılacak modeli belirlerken en sık kullanılan test yöntemi eğitilmiş modeli daha önce hiç karşılaşmadığı örnekler karşısında test etmektir. Kısacası modeli eğitmek için kullanılacak veriler ile test etmek için kullanılacak veriler farklı, fakat veri kaynağı aynı olmalıdır. Böylelikle modelin yeni karşılaştığı şartlar karşısındaki genelleme yeteneği adil ve tarafsız bir şekilde test edilmiş olur. Sahip olunan veri setinin eğitim ve test amaçlı olarak ikiye ayrılması en sık tercih edilen yöntemdir. Bu yöntem eğitim/test ayrımı olarak adlandırılır. Bu ayrım genellikle %70-%30, %80-%20 gibi oranlarla yapılır. Bu oranlardan ilki eğitim veri setinin, ikincisi test veri setinin oranıdır (Şekil 6.25). Farklı oranlar deneme yanılma şeklinde kullanılabilir. Fakat bu yöntemin küçük veri setleri için bir sakıncası vardır. Bu sakınca, ayrım işleminin rastgele yapılmasından dolayı, modelin öğrenmesi gereken faydalı bilgiler içeren örneklerin eğitim veri seti yerine test veri setinde daha çok toplanması ve bu nedenle eğitim veri setinde işin özünü ilgili


yeterli bilginin azalması olasıdır. Bu durumda öğrenme modeli kaliteli bir eğitim göremeyecek ve işin özünü kavrayamayacaktır. Bu nedenle eğitim/test ayrımı yöntemi daha çok, büyük veri setleri için uygundur.



Şekil 6.25. Eğitim/test veri ayrımı örneği.

Bu problemin üstesinden gelmek için çapraz doğrulama yöntemi geliştirilmiştir (Allen, 1974; Geisser, 1975). Çapraz doğrulama yöntemi, eğitim/test ayırımına benzetmekle birlikte, orijinal veri seti ilk önce, karar verilen sayıda (K) parçaya bölünür ve her döngüde farklı bir parça doğrulama amacıyla kullanılırken kalan diğer parçalar eğitim amacıyla kullanılır. Ardından tüm döngülerden elde edilen tahmin doğruluklarının ortalaması alınır (Şekil 6.26). Bu yöntem genel olarak K -katlı çapraz doğrulama (K -fold Cross Validation – K -fold CV) olarak adlandırılır. K değerinin seçimi için bir kural olmamakla birlikte, küçük veri setleri için 10, orta ve büyük veri setleri için sırasıyla 5 ve 3 değerleri yaygın olarak kullanılmaktadır. Büyük veri setleri için K değerinin büyük seçilmesi, çapraz doğrulama süreci için gereken işlemci gücünü ve işlem süresini çok fazla arttırmaktadır. Bu yöntemdeki K -katlı ayırma işlemi tüm veri setine uygulanabileceği gibi, ilk önce tüm veri seti eğitim/test ayırımına tabi tutulup, K -katlı ayırma işlemi sadece eğitim veri setinde uygulanabilir. Bu durumda elde edilen son model, hiç karşılaşmadığı test veri seti ile son bir kez daha test edilebilir. Bu kullanım şekli özellikle büyük veri setlerinde tercih edilir. Nispeten küçük veri setlerinde eğitim/test ayrımı yapmadan tüm veri seti K -katlı çapraz doğrulama için kullanılabilir. K -katlı çapraz doğrulamanın avantajı aslında teknik olarak bir test veri setine ihtiyaç duymamasıdır. Tüm veri seti çapraz doğrulamaya tabi tutulsa bile her döngüde 1 adet veri kümesi zaten doğrulama amacıyla kullanılmaktadır. Bu nedenle test verilerine sahip olunmadığı durumlarda ya da küçük veri setlerinde K -katlı çapraz doğrulama, modelin performansını daha gerçekçi bir şekilde ortaya koymaktadır. K -katlı çapraz doğrulama yönteminin her kat için hedef sınıf

dağılımının eşit yapıldığı ya da rastgele yapıldığı uygulama şekilleri mevcuttur. Hedef sınıf dağılımının eşit yapıldığı uygulama şeklinde kaç tane hedef sınıf varsa her kat veri bölümünde her sınıf türünden eşit ya da eşite en yakın örnek sayısında dağıtım yapılmaya çalışılır. Bu yöntem genellikle azınlık sınıflara sahip veri setleri için tercih edilmektedir. Bu tez çalışması kapsamında toplanan ölçüm örneklerinden elde edilen veri setinde hedef sınıf türlerinin bazıları (Case1, Case2, Case3) azınlık sınıflardır. Özellikle hatalı çalışma şeklinde etiketlenmiş örneklerin hedef sınıfları azınlık iken, normal çalışma şeklinde etiketlenmiş örnekler ise çoğunluğu oluşturmaktadır. Genel olarak bir FV güç sisteminde de normal çalışmaya dair örnekler, hatalı çalışmaya dair örneklere oranla daha çoktur.



Şekil 6.26. 10 katlı çapraz doğrulama örneği.

Tez çalışması kapsamında aday algoritmalarının optimizasyonu için şebeke-arama fonksiyonu kullanılmıştır. Bu fonksiyon Scikit-learn makine öğrenmesi kütüphanesi içerisinde yer alan bir arama fonksiyonudur. Şebeke-arama fonksiyonu bir öğrenme algoritması için en iyi parametre seçeneklerini bulmak amacıyla seçilen parametre değerleri üzerinde kapsamlı bir arama yapar. Arama işlemi sırasında çapraz doğrulama kullanan fonksiyon en iyi parametre seçeneklerini ve bu seçeneklerle alınmış tahmin doğruluklarını sonuç olarak raporlar.

Tez çalışması kapsamında kullanılması düşünülen aday algoritmaların varsayılan parametrelerine ek olarak Çizelge 6.7’de listelenen parametreler için şebeke-araması yapılmış ve en iyi sonucu veren parametreler kaydedilmiştir.

Çizelge 6.7. Algoritmalarda şebeke-araması yapılan parametreler.

DT	RF	ET	LR	GB
Düğümlere bölme yöntemi:	Düğümlere bölme yöntemi:	Düğümlere bölme yöntemi:	Optimizasyon algoritması:	Düğümlere bölme yöntemi:
gini/entropy	gini/entropy	gini/entropy	newton-cg/lbfgs/sag	friedman_mse/mse/mae
Bölme stratejisi:	Ağaç sayısı:	Ağaç sayısı:	Aşırı uyumlamaya karşı düzenleme eşik değeri:	
best/random	50/100/300	50/100/300	0,01/0,1/1/10/100	

Aday algoritmalarından QDA algoritmasının Scikit-learn uyarlamasında, performans ayarlaması yapılabilecek bir parametresi olmadığından bu algoritma varsayılan ayarlarıyla kullanılmıştır.

Kaydedilen parametreler kullanılarak optimize edilen algoritmaların eğitilmesi sonucu elde edilen modellerin tahmin kalitelerini ölçmek amacıyla tüm veri setinde 10-katlı çapraz doğrulama yapılmış ve modellerin aldıkları puanlar Çizelge 6.8’de listelenmiştir. Tahmin kalitesi için en düşük değer 0, en yüksek değer ise 1 olabilir. Bazı algoritmaların farklı parametreler için performansları birbirine yakın çıktığından aynı algoritmanın farklı parametrelere sahip sürümleri de test edilmiştir. Farklı sürümleri kullanılan algoritmalar ET ve RF algoritmalarıdır. Her iki algoritma, gini ve entropy düğümlere bölme yöntemleri ile farklılaştırılarak test edilmişlerdir. Bu algoritmalar ET_{gini} , ET_{ent} , RF_{gini} , RF_{ent} şeklinde adlandırılmışlardır. Çizelge 6.8’de görülen değerler Scikit-learn makine öğrenmesi kütüphanesindeki model değerlendirme paketinde yer alan çapraz doğrulama fonksiyonu *cross_val_score* ile elde edilmiştir. Değerler elde edilirken *f1-skoru* performans ölçütü tercih edilmiştir. Scikit-learn makine öğrenmesi kütüphanesinde, özellikle sınıflandırma problemlerinde yaygın olarak kullanılan performans ölçütleri Çizelge 6.9’da listelenmiştir.

Çizelge 6.8. Optimize edilmiş algoritmaların ortalama tahmin kaliteleri.

Algoritma	GB	QDA	ET _{gini}	ET _{ent}	DT	RF _{gini}	RF _{ent}	LR
Tahmin kalitesi	0,9514	0,9566	0,9597	0,9619	0,9588	0,9746	0,9746	0,9363
Standart sapma	0,0206	0,0255	0,0233	0,0219	0,0158	0,0151	0,0172	0,0556

Çizelge 6.9. Algoritmaların tahmin kalitesinde performans ölçütleri.

Puan türü	Açıklama	Hesaplama
Doğruluk	Modelin tahminleri ne sıklıkla doğru?	$\frac{TP + TN}{TP + TN + FP + FN}$
Kesinlik	Modelin pozitif tahmin ettikleri, ne sıklıkta doğru?	$\frac{TP}{TP + FP}$
Hatırlama	Gerçekten pozitif olanlar, ne sıklıkta doğru tahmin edilir?	$\frac{TP}{TP + FN}$
Belirginlik	Gerçekten negatif olanlar, ne sıklıkla doğru tahmin edilir?	$\frac{TN}{TN + FP}$
F1-skoru	Kesinlik ve hatırlama ağırlıklı ortalaması.	$2 * \frac{kesinlik * hatırlama}{kesinlik + hatırlama}$

Performans ölçütlerinin hesaplanmasında öğrenme modelinin yaptığı tahminlerle ortaya çıkan gerçek pozitif (True Positives – TP), gerçek negatif (True Negatives – TN), yanlış pozitif (False Positives – FP), yanlış negatif (False Negatives – FN) sayıları kullanılmaktadır. Bu sayıları, bir öğrenme modelinin bir tümör hakkında iyi huylu (negatif) ya da kötü huylu (pozitif) tahmini yapması ve bu tahminin doğru çıkıp çıkmaması şeklinde bir örnekle açıklamak gerekirse;

- Eğer model bir tümör için kötü huylu tahmini yapıyorsa ve tahmini doğru ise bu bir TP durumudur. Burada ikinci harf, modelin bir konu için yaptığı tahminin pozitif ya da negatif olmasını, birinci harf ise bu tahminin doğru çıkıp çıkmadığını belirtir.

- Eğer model bir tümör için iyi huylu tahmini yapıyorsa ve tahmini doğru ise bu bir TN durumudur.
- Eğer model bir tümör için kötü huylu tahmini yapıyorsa ve tahmini yanlış ise bu bir FP durumudur. Literatürde birinci tip hata olarak adlandırılır.
- Eğer model bir tümör için iyi huylu tahmini yapıyorsa ve tahmini yanlış ise bu bir FN durumudur. Literatürde ikinci tip hata olarak adlandırılır.

Farklı makine öğrenmesi problemlerinde farklı performans ölçütleri tercih edilebilir. Bununla birlikte, kullanılan veri setinin azınlık sınıflara sahip dengesiz bir veri seti olup olmaması da performans ölçütü seçimini etkilemektedir. Dengesiz bir veri setinde, bir performans ölçütüne göre oldukça başarılı görülebilecek bir model aslında azınlık sınıfların hiç birini doğru tahmin edememiş olabilir. Bu durum aşağıdaki örnekle açıklanabilir. Örneğin 1000 kişilik bir örnek grubundan alınmış verilerle oluşturulmuş bir veri setinde, tespit edilmiş tümörlerin iyi ya da kötü huylu olup olmadığı bir öğrenme modeli kullanılarak tahmin edilmek istensin. Modelin tahmin kalitesi ise *doğruluk* performans ölçütü ile değerlendirilsin. Bu 1000 kişiden 10'undaki tümörler gerçekten kötü huylu ise – ki bu bir dengesiz veri setine yol açar – ve kullanılan model 1000 örneğin hepsini iyi huylu olarak tahmin etmişse, bu modelin *doğruluk* performansı $\frac{TP+TN}{TP+TN+FP+FN} = \frac{0+990}{0+990+0+10} = 0,99$ olarak hesaplanır. Modelin %99'a karşılık gelen *doğruluk* performansı oldukça yüksek görünse de kötü huylu tümöre sahip kişilerin hiç biri model tarafından tespit edilememiştir. *Kesinlik* performans ölçütü ise, yüksek FP hatası veren modelleri iyileştirmek için takip edilmesi gereken bir ölçüttür. Bir örnekle açıklamak gerekirse, bir tümörün iyi ya da kötü huylu olduğunu söyleyen bir model düşük *kesinlik* performansı gösteriyorsa, çoğu iyi huylu tümör sahibi hastaya kötü huylu tümörleri olduğu söylenmiş olabilir. Bu durumda yanlış alarmları azaltmak amacıyla modelin *kesinlik* performansı geliştirilmeye çalışılır. Benzer şekilde *hatırlama* performans ölçütü ise, FN hatalarını azaltmak amacıyla kullanılmaktadır. Yukarıdaki örneklerden yola çıkılırsa, *hatırlama* performansı düşük bir model, kötü huylu tümör sahibi olan hastalara, tümörlerinin iyi huylu olduğunu söylemektedir. Bu iki örnekten anlaşılacağı üzere, FN hataları, FP hatalarına göre daha vahim sonuçlar doğurabilir. Her iki performans ölçütünün dengelenmek istendiği durumlarda ise *f1-skoru* performans ölçütü tercih edilebilir. Yüksek bir *f1-skoru*

performansına sahip model, düşük FP ve FN hataları verecektir. Genellikle bir hata türünün azaltılması, diğerinin artmasıyla sonuçlanabilir, bu nedenle iki hatayı dengelemek önemlidir. TP ve TN durumları istenen durumlardır ve bu sayıların yüksek çıkması modelin başarılı tahmin yaptığını gösterir. Tüm durumların görsel ifadesi için, yaygın olarak karışıklık matrisi kullanılır. Şekil 6.27’de iki hedef sınıfı içeren örnek bir karışıklık matrisi gösterilmiştir.

	Sınıf 1 tahmin	Sınıf 2 tahmin
Sınıf 1 gerçek	TP	FN
Sınıf 2 gerçek	FP	TN

Şekil 6.27. Karışıklık matrisi örneği.

FV güç sistemleri için her iki hata türünün azaltılması önemli olsa da, bu sistemlerin yüksek maliyeti ve uzun amortisman sürelerinden dolayı, bir hata gerçekleştiğinde bu hatanın yok sayılmaması daha önemlidir. Bu nedenle hata tespitinde düşük FN hatalarına sahip, yüksek *hatırlama* performanslı bir model, düşük FP hatalarına sahip, yüksek *kesinlik* performanslı bir modele tercih edilebilir. Bununla birlikte bu iki hatanın da gözetildiği, yüksek *f1-skoru* performanslı bir model de tercih edilebilir. Bu tez çalışması kapsamında kullanılan tüm öğrenme modellerinin ve geliştirilen topluluk öğrenmesi modelinin test edilmesinde performans ölçütü olarak *f1-skoru* tercih edilmiştir.

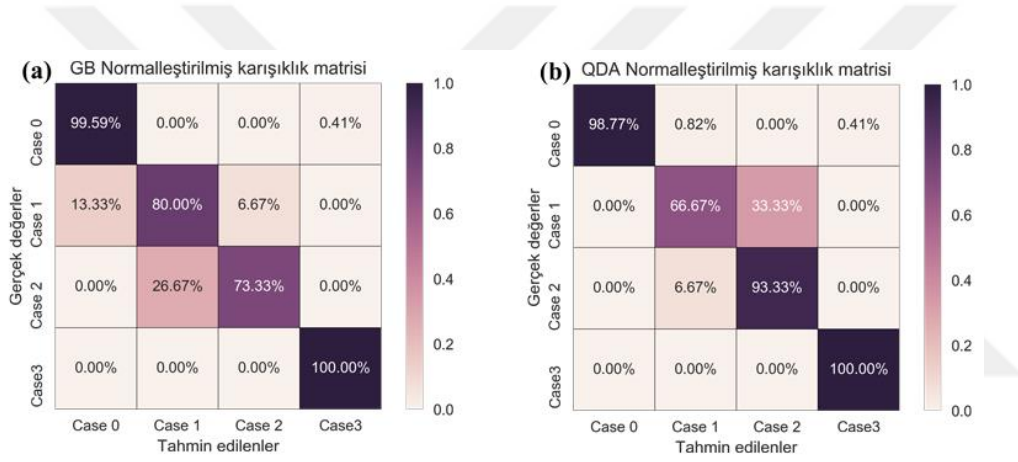
Bununla birlikte öğrenme modellerinin sınıflandırma performansları da modellerin test edilmesi açısından önemli bir diğer ölçüttür. Bu amaçla optimize edilmiş algoritmalarından elde edilen modellerin test veri setindeki normal ve hatalı çalışma koşullarını doğru tahmin edebilme (sınıflandırma) oranları Çizelge 6.10’da listelenmiştir. Bu çizelgedeki tahmin doğrulukları ile Çizelge 6.8’deki *f1-skoru* ile elde edilmiş tahmin kaliteleri farklı değerler içerse de her iki gösterim şekli modellerin performanslarını göstermek için kullanılmaktadır.

Çizelge 6.10. Algoritmaların hata tipleri için tahmin doğrulukları.

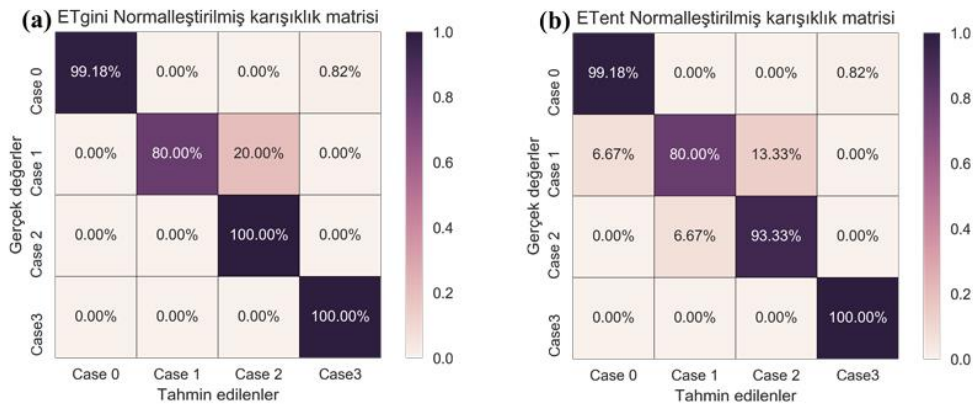
Algoritma	Normal çalışma (Case 0)	Dizideki bir panelin gölgelenmesi (Case 1)	Dizideki iki panelin gölgelenmesi (Case 2)	Dizideki bir panelde kısa devre olması (Case 3)	Algoritma ortalaması
GB	%99,59	%80,00	%73,33	%100,00	%88,23
QDA	%98,77	%66,67	%93,33	%100,00	%89,69
ET_{gini}	%99,18	%80,00	%100,00	%100,00	%94,80
ET_{ent}	%99,18	%80,00	%93,33	%100,00	%93,13
RF_{gini}	%99,59	%60,00	%100,00	%100,00	%89,90
RF_{ent}	%99,59	%66,67	%100,00	%100,00	%91,57
DT	%98,77	%80,00	%100,00	%100,00	%94,69
LR	%98,77	%93,33	%46,67	%63,64	%75,60

Çizelge 6.10'daki değerlerin görsel ifadesi olan, her bir modele ait karışıklık matrisleri ise Şekil 6.28.(a)(b), Şekil 6.29.(a)(b), Şekil 6.30.(a)(b) ve Şekil 6.31.(a)(b)'de görülmektedir. Matrisler her bir hedef sınıfı için öğrenme modellerinin hem doğru hem de yanlış sınıflandırma oranlarını gösterir. Veri setinde, her bir hata tipindeki örnek sayısı farklı olduğundan tüm karışıklık matrisleri normalleştirilmiştir. Normalleştirilmiş karışıklık matrisinin her bir satırı o hedef sınıfı için yapılan tahmin sayısının hedef sınıfındaki gerçek örnek sayısına oranlarını içeren hücrelerden oluşmaktadır. Örneğin Şekil 6.28.(a)'da üstten ikinci satır olan Case 1 satırında, soldan ilk hücrede %13,33 değeri bulunmaktadır. Bu değer, Case 1 sınıfına yani FV dizideki tek bir panelin gölgelenmeye maruz kaldığı çalışma şartlarına ait olan örneklerin %13,33'ünün GB algoritması tarafından Case 0 yani FV dizide herhangi bir hata yok şeklinde tahmin edildiğini gösterir ki bu yanlış yapılmış bir tahmindir ve bir FN durumudur. Aynı satırdaki soldan üçüncü hücre ise Case 1 sınıfına ait örneklerin %6,67'sinin Case 2 olarak tahmin edildiğini gösterir. Diğer bir deyişle FV dizideki tek bir panelin gölgelendiği hata senaryolarından elde edilmiş örneklerin %6,67'si, GB algoritması tarafından iki panel gölgelenmiştir şeklinde tahmin edilmiştir. Sonuç olarak, GB algoritması FV dizideki tek bir panelin gölgelendiği çalışma koşullarında elde edilmiş örneklerin sadece %80'ini doğru tahmin edebilmiştir.


Tüm modeller test veri setindeki normal çalışma şartlarına ait örnekler için yüksek tahmin doğruluğu gösterirken, dizideki tek bir panelin gölgelenmesi hatalarını nispeten daha düşük doğrulukla tahmin edebilmişlerdir. LR modeli tek panelin gölgelenmesi hatalarını en yüksek doğrulukla (%93,33) tahmin edebilen model olmuştur. Dizideki iki panelin gölgelenmesi hatalarının tahmin edilmesinde GB ve LR modelleri düşük performans gösterirken diğer tüm modeller bu hata tipini yüksek doğrulukta tahmin edebilmişlerdir. FV dizideki bir panelin kısa devre olması hatası için ise LR modeli dışında diğer tüm modellerde %100'lük tahmin doğruluğu elde edilmiştir. LR modeli hem iki panelin gölgelenmesi hatalarında hem de tek panelin kısa devre olması hatalarında en düşük tahmin performansını sergileyen model olmuştur.




Şekil 6.28. Normalleştirilmiş karışıklık matrisleri (a) GB, (b) QDA.



Şekil 6.29. Normalleştirilmiş karışıklık matrisleri (a) ET_{gini} , (b) ET_{ent} .



Şekil 6.30. Normalleştirilmiş karışıklık matrisleri (a) RF_{gini} , (b) RF_{ent} .



Şekil 6.31. Normalleştirilmiş karışıklık matrisleri (a) DT, (b) LR.

6.3.4. Topluluk modelinin oluşturulması

Ortaya çıkacak son topluluk modeli hata tiplerinin sınıflandırmasında en azından tüm bireysel modeller kadar başarılı olmalıdır. Topluluk modelinin oluşturulması için GB, QDA, ET_{gini} , ET_{ent} , DT, RF_{gini} , RF_{ent} ve LR algoritmalarından ikili, üçlü ve dörtlü aday gruplar oluşturulmuştur. İkili, üçlü ve dörtlü grup sayısı 168 adettir. Bunlardan 28'i ikili gruplar, 56'sı üçlü gruplar, kalan 84 adedi ise dörtlü gruplardır.

Topluluk modellerinin oluşturulmasında Scikit-learn makine öğrenmesi kütüphanesinde topluluk öğrenme modelleri paketinde yer alan *VotingClassifier*

sınıflandırıcısı tercih edilmiştir. Bu sınıflandırıcı, kavramsal olarak farklı öğrenme algoritmalarını birleştirerek hedef sınıfı tahmin etmeye çalışır. Bu tahminin nasıl yapılacağını kullanıcı belirler. Belirleme işlemi *VotingClassifier* sınıflandırıcısının iki yapısal parametresi ayarlanarak yapılabilir. Bu yapısal parametrelerden ilki oylama tipi (*voting*) parametresidir. Oylama tipi parametresi, oy çokluğu (*hard*) ya da tahmin olasılıklarının ortalaması (*soft*) şeklinde seçilebilir. Örneğin, oy çokluğu tipinde oylama (*hard-voting*) yapan bir topluluk modeli üç farklı öğrenme algoritması içeriyorsa ve algoritmaların üçte ikisi test örneğini *Sınıf1* olarak, üçte biri ise *Sınıf2* olarak sınıflandırıyorsa, test örneği oy çokluğuyla *Sınıf1* olarak sınıflandırılır. Oy çokluğuna göre algoritmaların tahminlerinden en son tahminin elde edilmesi işlemi aşağıdaki eşitlikte görüldüğü gibi gerçekleştirilir.

$$y' = \text{mode}\{A_1(x), A_2(x), \dots, A_N(x)\} \quad (6.3)$$

Burada $A_N(x)$ belirli bir x örneği için N . algoritmanın yaptığı sınıflandırma tahminidir.

İkinci yapısal parametre ise ağırlıklar parametresidir. Örneğin “*soft-voting*” tipinde ayarlanmış bir topluluk modelinde, ağırlıklar parametresi de $[1,1,1]$ şeklinde ayarlanmışsa her bir algoritmanın bir örnek için yaptığı tahmin olasılığı 1 ile çarpıldıktan sonra tüm olasılıkların ortalamaları hesaplanır ve topluluk modelinin tahmin sonucu olarak belirlenir. Eğer ağırlıklar $[2,1,1]$ şeklinde ayarlanmışsa, ilk algoritmanın tahmin olasılığı 2 ile çarpılırken, ikinci ve üçüncü algoritmanın tahmin olasılıkları 1 ile çarpılır. Tahmin olasılıklarının ağırlıklı ortalamasına göre algoritmaların tahminlerinden en son tahminin elde edilmesi işlemi ise aşağıdaki eşitlikte görüldüğü gibi gerçekleştirilir.

$$y' = \text{argmax} \sum_{n=1}^N w_n P_{ni} \quad (6.4)$$

Burada w_n n. algoritmaya atanmış ağırlık değeri, P_{ni} ise n. algoritmanın hedef sınıflardan biri olan i . sınıf için yaptığı tahminin olasılığıdır. *Argmax* fonksiyonu parametreleri arasında en büyük olanın sıra numarasını sonuç olarak veren bir fonksiyondur. Örneğin hedef sınıfları $i \in \{\text{Sınıf1}, \text{Sınıf2}\}$ olan bir sınıflandırma

işleminde A_1, A_2, A_3 algoritmaları kullanılsın ve her algoritmanın belirli bir x örneği için hedef sınıf tahmin olasılıkları sırasıyla aşağıda gibi olsun.

- $A_1(x) = [0,9 \ 0,1]$
- $A_2(x) = [0,8 \ 0,2]$
- $A_3(x) = [0,4 \ 0,6]$

Eğer her algoritma için eşit ağırlıklar kullanılırsa, bu üç algortmadan oluşan topluluk modelinin x örneği için *Sınıf1* tahmininde bulunma olasılığı $P(i_1|x) = (0,9 + 0,8 + 0,4)/3 = 0,7$ olarak, *Sınıf2* tahmininde bulunma olasılığı ise $P(i_2|x) = (0,1 + 0,2 + 0,6)/3 = 0,3$ olarak hesaplanır. Eşitlik 6.4'e göre $y' = \operatorname{argmax}[P(i_1|x), P(i_2|x)] = \operatorname{argmax}[0,7 \ 0,3] = 1$ olduğundan, $\{Sınıf1, Sınıf2\}$ hedef sınıflarında 1. değer olan *Sınıf1*, topluluk modelinin en son tahmini olarak kabul edilir.

Algoritmalar için farklı ağırlıklar atandığı durumlarda ise algoritmaların tahmin olasılıkları ile ağırlıkların çarpımları toplanarak hedef sınıf için son tahmin elde edilir. Örneğin A_1, A_2 ve A_3 algoritmalarına atanmış ağırlıklar sırasıyla aşağıdaki gibi olsun.

- $w_1 = 0,1$
- $w_2 = 0,1$
- $w_3 = 0,8$

Bu durumda topluluk modelinin x örneği için *Sınıf1* tahmininde bulunma olasılığı $P(i_1|x) = 0,1 * 0,9 + 0,1 * 0,8 + 0,8 * 0,4 = 0,49$ olarak, *Sınıf2* tahmininde bulunma olasılığı ise $P(i_2|x) = 0,1 * 0,1 + 0,1 * 0,2 + 0,8 * 0,6 = 0,51$ olarak hesaplanır. Eşitlik 6.4'e göre $y' = \operatorname{argmax}[P(i_1|x), P(i_2|x)] = \operatorname{argmax}[0,49 \ 0,51] = 2$ olduğundan, $\{Sınıf1, Sınıf2\}$ hedef sınıflarında 2. değer olan *Sınıf2*, topluluk modelinin en son tahmini olarak kabul edilir.

Tez çalışması kapsamında ilk olarak tüm aday modeller herhangi bir parametre optimizasyonu yapılmadan varsayılan ayarlarla *VotingClassifier* sınıflandırıcısı ile oluşturulmuşlardır. Burada amaç, modellerin herhangi bir

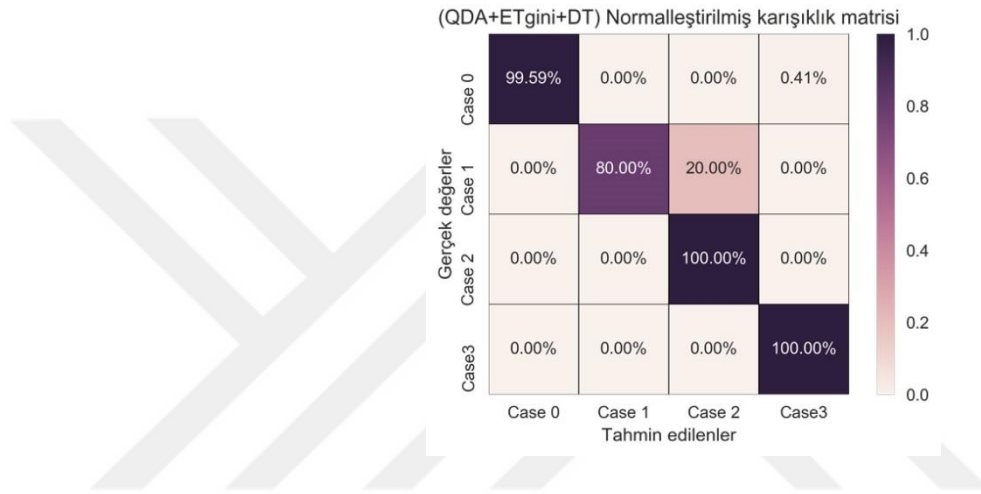
optimizasyon olmadan sergileyeceği performansı ölçmektir. Oluşturulan tüm topluluk modelleri, 10 katlı çapraz doğrulama ile tahmin kaliteleri açısından test edilmiştir. Bu işlemde de *f1-skoru* performans ölçütü kullanılmıştır. Çizelge 6.11’de en başarılı ortalama tahmin kalitelerine sahip ilk beş aday topluluk modeli listelenmiştir. Çizelge 6.11’de ayrıca aday topluluk modelini oluşturan algoritmaların bireysel tahmin kaliteleri ve bu bireysel kalitelerinin ortalamaları da gösterilmiştir. Çizelgede ilk sırada olan topluluk modeli QDA + ET_{gini} + DT algoritmalarından oluşmaktadır. Görüleceği gibi bu üç algoritmanın tahmin kalitelerinin ortalaması en düşük olmasına rağmen, oluşturdukları aday topluluk modeli en yüksek tahmin kalitesine ulaşmıştır. Çizelgede görüleceği gibi bireysel tahmin kaliteleri nispeten yüksek algoritmaların kullanılması, topluluk modelinin tahmin kalitesini artırmayabilir.

Çizelge 6.11. En başarılı aday topluluk modellerinin ortalama tahmin kaliteleri.


Aday topluluk modeli ve algoritmaları	Topluluk tahmin kalitesi	Standart sapma	Algoritmaların tahmin kaliteleri	Kalitelerin ortalaması
QDA+ ET_{gini} +DT	0,9788	0,0142	0,9566 / 0,9597 / 0,9588	0,9584
QDA+ ET_{gini} + RF_{gini}	0,9788	0,0150	0,9566 / 0,9597 / 0,9746	0,9636
QDA+ ET_{gini} + RF_{ent}	0,9778	0,0153	0,9566 / 0,9597 / 0,9746	0,9636
QDA+ ET_{ent} +DT	0,9778	0,0146	0,9566 / 0,9619 / 0,9588	0,9591
GB+QDA+ RF_{ent}	0,9768	0,0163	0,9514 / 0,9566 / 0,9746	0,9609

Başarılı beş aday topluluk modeline ait karışıklık matrisleri Şekil 6.32, Şekil 6.33, Şekil 6.34, Şekil 6.35 ve Şekil 6.36’da görülmektedir. Çizelge 6.11’e göre 1. ve 2. aday topluluk modelleri en yüksek ortalama tahmin kalitesine sahip görünmektedir. Şekil 6.32 ve Şekil 6.33’te görüldüğü gibi normal çalışma, iki panelin gölgelenmesi ve tek panelin kısa devre olması hataları için eşit sınıflandırma performansı gösteren bu iki topluluk modeli tek panelin gölgelenmesi hatası için farklı performans sergilemiştir. Burada 1. aday topluluk modeli öne çıkarak tek panelin gölgelenmesi hatası için daha yüksek bir sınıflandırma performansına ulaşmıştır. 2. ve 3. aday topluluk modelleri Şekil 6.33 ve Şekil 6.34’te ki karışıklık matrislerinde görüldüğü gibi tüm hedef sınıflarda eşit sınıflandırma performansı göstermişlerdir. 3. aday model ile aynı tahmin kalitesine


sahip 4. modelde iki panelin gölgeleme hatası için sınıflandırma performansı bir miktar kayıpla %93,33'e düşerken, diğer hedef sınıfları için sınıflandırma performansı korunmuştur. 5. aday model ise 4. modelin sınıflandırma performansını normal çalışma, iki panelin gölgeleme ve tek panelin kısa devre olması hataları için yakalasa da tek panelin gölgeleme hatasında bu performans %66,67'ye kadar gerilemiştir. Karışıklık matrislerinden görüleceği gibi her aday model kendinden bir önceki daha başarılı aday modele göre genellikle bir hedef sınıfı için giderek azalan bir sınıflandırma performansı sergilemiştir.




Şekil 6.32. 1. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.




Şekil 6.33. 2. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.



Şekil 6.34. 3. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.



Şekil 6.35. 4. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.




Şekil 6.36. 5. Aday topluluk modeli normalleştirilmiş karışıklık matrisi.

Oluşturulan tüm topluluk modelleri içerisinde 10 katlı çapraz doğrulama sonucu elde edilen tahmin doğruluklarında en düşük performanslar ikili gruplardan gelmiştir. Dörtlü gruplar ise performans bakımından ikili gruplar ile üçlü gruplar arasında yer almıştır. Çizelge 6.12’de en başarısız tahmin kalitelerine sahip beş aday topluluk modeli listelenmiştir. Çizelgede yer alan tüm aday topluluk modellerinin tahmin kaliteleri, aday topluluk modelini oluşturan algoritmaların tahmin kalitelerinin ortalamasının altındadır.

Çizelge 6.12. En başarısız aday topluluk modellerinin ortalama tahmin kaliteleri.

Aday topluluk modeli ve algoritmaları	Topluluk tahmin kalitesi	Standart sapma	Algoritmaların tahmin kaliteleri	Kalitelerin ortalaması
GB+LR	0,9312	0,0235	0,9514 / 0,9363	0,9439
DT+LR	0,9376	0,0192	0,9588 / 0,9363	0,9476
GB+ ET_{gini}	0,9408	0,0217	0,9514 / 0,9597	0,9556
GB+ ET_{ent}	0,9419	0,0236	0,9514 / 0,9619	0,9567
ET_{gini} +DT	0,9429	0,0178	0,9597 / 0,9588	0,9593

Çizelgede ilk sırada yer alan aday model tüm topluluk modelleri içerisinde en başarısız olanıdır. Şekil 6.37’de bu topluluk modeline ait normleştirilmiş karışıklık matrisi görülmektedir.



Şekil 6.37. En başarısız topluluk aday modelin normleştirilmiş karışıklık matrisi.

Bu topluluk modelinin tahmin kalitesi, modeli oluşturan GB ve LR algoritmalarının bireysel tahmin kalitelerinin de altındadır. Özellikle ikili gruplarda bu iki algoritmadan birinin dâhil olduğu topluluk modelleri düşük performans sergileyen modeller olmuşlardır.

6.3.5. Topluluk modelinin optimizasyonu

En başarılı aday topluluk modelleri bulunduktan sonra, son topluluk modeline karar vermek için *VotingClassifier* sınıflandırıcısı, oylama tipi ve ağırlıklar parametreleri değiştirilerek kapsamlı bir dögüsel arama yapılmıştır. Bu arama işlemi için Çizelge 6.11’de listelenen tüm aday topluluk modelleri Çizelge 6.13’te görölen farklı oylama tipleri ve farklı algoritma ağırlıkları ile 10 katlı çapraz doğrulama yapılarak test edilmiştir.

Çizelge 6.13. Topluluk modelinde oylama tipi ve ağırlıklar parametreleri için seçenekler.

Parametreler	Seçenekler
Oylama tipi	‘soft’, ‘hard’
Ağırlıklar	[1,1,1], [1,1,2], [1,2,1], [2,1,1], [1,2,2], [2,2,1], [2,1,2]

Gerçekleştirilen arama işlemi sonunda 1. aday topluluk modeli (QDA+ ET_{gini} +DT) ‘soft’ oylama tipi ve [2,1,2] algoritma ağırlıklarıyla optimize edildiğinde yine en başarılı model olmuş ve son topluluk modeli olarak seçilmiştir. Çizelge 6.14’te son topluluk modelinin *f1-skoru* ile elde edilmiş ortalama tahmin kalitesi gösterilmiştir. Optimizasyon ile topluluk modelinin %97,88 olan ortalama tahmin kalitesi %98,10’a çıkmıştır.


Çizelge 6.14. Son topluluk modelinin ortalama tahmin kalitesi.

En başarılı topluluk modeli	Optimizasyon öncesi tahmin kalitesi	Optimizasyon sonrası tahmin kalitesi	Standart sapma
QDA+ ET_{gini} +DT	0,9788	0,9810	0,0184

Şekil 6.38’de optimize edilmiş son topluluk modelinin normalleştirilmiş karışıklık matrisi görölmektedir. Şekilde göröldüğü gibi optimize edilmiş son topluluk modeli, test veri seti için FV dizinin normal çalışması, FV dizideki iki

panelin gölgelenmesi ve tek panelin kısa devre olması durumlarında optimizasyon öncesiyle aynı tahmin doğruluklarını yakalamış, bununla birlikte FV dizideki tek panelin gölgelenmesi durumlarında %80 olan optimizasyon öncesi tahmin doğruluğunu %86,67'ye taşımıştır. Sonuç olarak yapılan optimizasyon ile topluluk modelinin tüm normal ve hatalı çalışma durumları için %94,90 olan ortalama tahmin doğruluğu %96,57'ye çıkmıştır.

Elde edilen son topluluk modeli ilk olarak PC üzerinde oluşturulmuş, eğitilmiş ve test edilmiştir. Fakat bu modelin bulut katmanında çalıştırılabilmesi için sunucu tarafına taşınması gereklidir. Bir sonraki bölümde modelin sunucuya taşınması ve çalıştırılması anlatılmıştır.



Şekil 6.38. Son topluluk modelinin normalleştirilmiş karışıklık matrisi.

6.4. Hata Tespit Sisteminin Bulut Katmanında Çalıştırılması

PC'de çevrimdışı olarak geliştirilen son topluluk modeli bu haliyle dış kullanıma kapalıdır. Modelin istemci sunucu mimarisine uygun şekilde sunucu tarafında çalıştırılması, FV izleme sistemindeki hata tespit yeteneğinin de bulut bağlantılı hale getirilmesini sağlayacaktır. Son topluluk modelini, eğitilmiş haliyle ve mevcut genelleme yeteneği ile sunucu tarafına taşımak gereklidir. Bunun için Python nesnelerini sayısal dosya olarak kaydetmeyi sağlayan Joblib¹ yazılım kütüphanesinden faydalanılmıştır. Şekil 6.39'da sayısal dosya olarak kaydedilen

¹ <https://joblib.readthedocs.io/en/latest/> erişim tarihi 1 Mart 2019.

son topluluk modelinin metin editörü ile açılmış içeriği görülmektedir. 25 binin üzerinde satırdan oluşan dosyanın boyutu 397KB'dır.

```

1 8003 6373 6b6c 6561 726e 2e65 6e73 656d
2 626c 652e 766f 7469 6e67 5f63 6c61 7373
3 6966 6965 720a 566f 7469 6e67 436c 6173
4 7369 6669 6572 0a71 0029 8171 017d 7102
5 2858 1100 0000 6e61 6d65 645f 6573 7469
6 6d61 746f 7273 5f71 0363 736b 6c65 6172
7 6e2e 7574 696c 730a 4275 6e63 680a 7104
8 2981 7105 2858 0200 0000 7164 7106 6373
9 6b6c 6561 726e 2e64 6973 6372 696d 696e
10 616e 745f 616e 616c 7973 6973 0a51 7561
:
:
:
25393 0000 0003 0000 0000 0000 0075 6268 5d68
25394 5e6a fb05 0000 5d72 110a 0000 2868 0868
25395 c468 7265 6adc 0500 0068 0c29 8172 120a
25396 0000 7d72 130a 0000 2868 0f68 1068 1168
25397 7d68 1888 6819 681a 681b 4b04 8572 140a
25398 0000 7562 0000 0000 0000 0000 0100 0000
25399 0000 0000 0200 0000 0000 0000 0300 0000
25400 0000 0000 5806 0000 0076 6f74 696e 6772
25401 150a 0000 5804 0000 0073 6f66 7472 160a
25402 0000 7562 2e

```

Şekil 6.39. Sayısal dosya olarak kaydedilen topluluk modeli içeriği.

Joblib kütüphanesi yardımı ile aynı zamanda bir Python nesnesi olan son topluluk modeli tekrar eğitimeye gerek duymadan sunucu tarafına yüklenerek çalıştırılabilecektir. Eğer model ilerleyen zamanlarda yeni eğitim verileri ile eğitilmek istenirse, eğitim işlemi PC tarafında yapılarak eğitilmiş model tekrar sunucuya yüklenebilir. Diğer bir seçenek ise eğitim verilerinin sunucuya yüklenip eğitim işleminin sunucu tarafında yapılmasıdır.

Eğitilmiş topluluk modeli sunucuya yüklendikten sonra HTWS kendisine gelen ilk http isteği ile çalışmaya başlar. İlk olarak sunucuya yüklenmiş olan sayısal dosyadan son topluluk modelini çıkarır ve bunu sunucu belleğine yükler. Bu işlem yine Joblib yazılım kütüphanesi fonksiyonları ile gerçekleştirilir. Modelin belleğe yüklenmesi ile bundan sonra gelen her http isteğinde sayısal dosyanın tekrar açılıp modelin dosyadan çıkarılmasına gerek kalmaz. Sayısal dosyanın açılıp okunması işlemci gücü ve zaman gerektiren bir işlem olduğundan, gelen ilk http isteğiyle birlikte modelin belleğe yüklenmesi sağlanmıştır. Sunucu platformu olarak kullanılan Heroku, 30 dakika boyunca herhangi bir web trafiği olmazsa HTWS sistemini uyku durumuna almaktadır. Uyku durumundaki HTWS sistemine yeni bir http isteği geldiğinde Heroku platformu HTWS sistemini tekrar aktif hale getirir ve son topluluk modeli, sayısal dosyadan tekrar çıkarılıp belleğe yüklenir.

HTWS kendisine gelen http isteğindeki paket haline getirilmiş FV izleme verilerini parçalara ayırır. Eksik ya da fazla parça olduğunda geriye cevap olarak hata mesajı gönderir. Bu parçalar özellik seçimiyle kullanılması kararlaştırılmış olan V_{str} , I_{str} , P_{str} , G , T_c verileridir. T_c verisi gelen http isteğindeki pakette yer alan T_m verisinden türetilir. Bu veriler sunucu belleğinde yüklü olan topluluk modeli tarafından okunur. Model bu verilerden yola çıkarak verileri sınıflandırır. Kısacası verilerin hangi hedef sınıfa dâhil olabileceği hakkında bir tahmin üretir. Gelen verilerin sınıflandırılması aslında FV sistemin normal mi yoksa hatalı mı, hatalı ise hangi türde hata ile çalıştığını tespit etme işlemidir. Modelin yaptığı tahminler ise JSON formatında http cevabı olarak istemciye geri gönderilir. Burada istemci, bu tez çalışmasındaki asıl istemci olan Esp birimi ya da herhangi bir web, masaüstü ya da mobil tabanlı istemci olabilir.

Şekil 6.40, Şekil 6.41, Şekil 6.42 ve Şekil 6.43'te sırasıyla Case 0, Case 1, Case 2 ve Case 3 şeklinde yapılmış tahminler görülmektedir. Şekillerdeki tüm tahminler web tarayıcısından gelen http istekleri üzerine yapılmıştır. İsteği yapan istemci bir web tarayıcısı olduğu için HTWS sisteminden gelen JSON formatındaki cevap yine bu web tarayıcısı ekranında gösterilir. Modern web tarayıcıları JSON formatındaki bilgiyi şekillerde görüldüğü gibi tablo yapısında ve kolay okunabilir bir biçimde gösterebilirler. Gelen cevap içerisinde aşağıdaki bilgiler yer almaktadır:

- *Predicted_case*: FV sistemin o andaki çalışma durumu tahmini (Case 0, Case 1, Case 2, Case 3).
- *Prediction_probability*: Yapılan tahmin için öngörülen olasılık değeri (0 değeri %0, 1 değeri ise %100'e eşittir). Örneğin yapılan tahmin Case 1 şeklinde ise *Prediction_probability* ile *Case1_probability* birbirine eşit olmaktadır.
- *Case0_probability*: Case 0 durumu için öngörülen olasılık değeri.
- *Case1_probability*: Case 1 durumu için öngörülen olasılık değeri.
- *Case2_probability*: Case 2 durumu için öngörülen olasılık değeri.
- *Case3_probability*: Case 3 durumu için öngörülen olasılık değeri.
- V_{str} , I_{str} , P_{str} , G , T_c : Tahminin hangi ölçüm verilerine karşılık yapıldığı.
- *Run_time*: Tahminin sunucu tarafında üretilme süresi.

Üst bilgiler	
G:	524.83
Istr:	270.847
Pstr:	8152.8828
Tc:	49.45
Tm:	47.88
Vstr:	30.101
case0_probability:	0.9832561945324688
case1_probability:	0.008879440039173861
case2_probability:	0.007690200391771205
case3_probability:	0.00017416503658624938
predicted_case:	"0"
prediction_probability:	"0.9832561945324688"
run_time:	0.007236999999999938

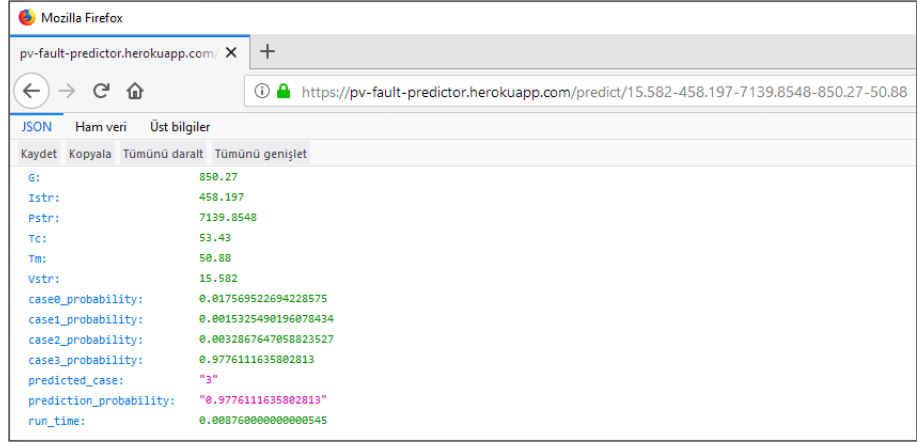
Şekil 6.40. Bir test örneği için yapılmış normal çalışma tahmini.

Üst bilgiler	
G:	779.57
Istr:	261.356
Pstr:	8757.9033
Tc:	53.47
Tm:	51.13
Vstr:	33.507
case0_probability:	0.0748435347371273
case1_probability:	0.8857834534305897
case2_probability:	0.03863727539817445
case3_probability:	0.0007357364341085271
predicted_case:	"1"
prediction_probability:	"0.8857834534305897"
run_time:	0.011591000000000129

Şekil 6.41. Bir test örneği için yapılmış tek panelin gölgeleme hatası tahmini.

Üst bilgiler	
G:	765.86
Istr:	251.468
Pstr:	7792.771
Tc:	52.18
Tm:	49.88
Vstr:	31.016
case0_probability:	0.06051947448585193
case1_probability:	0.12642298394094614
case2_probability:	0.8092224354248699
case3_probability:	0.003835106140331955
predicted_case:	"2"
prediction_probability:	"0.8092224354248699"
run_time:	0.007048000000000165

Şekil 6.42. Bir test örneği için yapılmış iki panelin gölgeleme hatası tahmini.



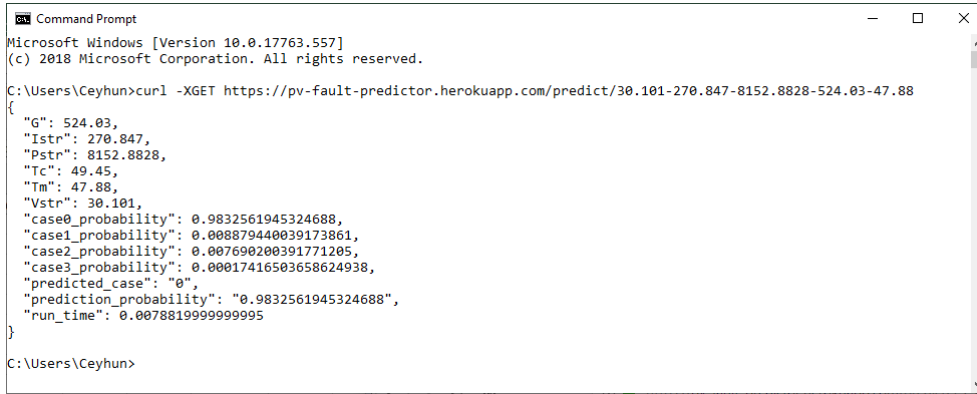
Şekil 6.43. Bir test örneği için yapılmış tek panelin kısa-devre hatası tahmini.

Örneğin Şekil 6.40'a göre, HTWS sistemine yapılan tahmin isteği web tarayıcının adres kısmına girilen pv-fault-predictor.herokuapp.com/predict/30.101-270.847-8152.8828-524.03-47.88 adres satırı ile olmuştur. HTWS tarafından yapılan tahmin, isteği yapan istemciye JSON formatında bir cevap olarak gönderilir.

Web tarayıcıya gelen cevabın ekran görüntüsünü gösteren Şekil 6.40'dan da anlaşılacağı gibi FV dizinin içinde bulunduğu şartlar $524,03\text{W/m}^2$ ışınım şiddeti ve $47,88^\circ\text{C}$ panel arka yüzey sıcaklıkları ortalamasıdır. FV dizi, bu şartlarda $270,847\text{mA}$ akım, $30,10\text{V}$ gerilim ve $8152,88\text{mW}$ güç çıkışı vermiştir. Güç çıkışı değerleri HTWS sisteminin tahmin ettiği bir bilgi değil, HTWS sistemine iletilen bir bilgidir ve bu bilgiler ışığında bir tahmin yapması istenmiştir. HTWS sistemi kendisine gönderilen panel arka yüzey sıcaklığı ortalaması değerini panel hücre sıcaklığı değerine çevirerek kullanır. Yapılan tahmin ise bu ışınım ve arka planda hesaplanan hücre sıcaklığı şartlarında FV diziden üretilen akım, gerilim ve güç çıkışlarının normal olduğu ve herhangi bir hata olmadığı şeklindedir. Cevapta, yapılan tahmin için öngörülen olasılık yaklaşık olarak %98,33 olarak belirtilmiştir. Şekil 6.40'a göre, HTWS tarafından diğer çalışma durumları için öngörülen olasılıklar tek panelin gölgeleneme durumu (Case 1) için yaklaşık %0,89, iki panelin gölgeleneme durumu (Case 2) için yaklaşık %0,77 ve tek panelin kısa devre olması durumu (Case 3) için ise yaklaşık %0,01 olarak cevaplanmıştır. Tahminin sunucu tarafında üretilmesi 0,007 saniye sürmüştür. Bu süreye HTWS sistemine gelen http isteğindeki veri paketinin parçalara ayrılması ve bu parçalardaki verilerin

kullanılarak topluluk modeli tarafından tahmin yapılması da dâhildir. Tüm hata tespit süreci düşünüldüğünde ise deneysel sistemden verilerin toplanması, verilerin sunucu tarafına gönderilmesi, bir tahmin yapılması ve tahminin istemciye geri gönderilmesi dâhil tüm süreç birkaç saniye sürmektedir.

Şekil 6.44'te komut satırından curl aracıyla yapılmış bir tahmin isteği ve HTWS tarafından gönderilen JSON formatındaki cevap görülmektedir. Şekilde görüleceği gibi yapılan tahmin isteği Şekil 6.40'taki ile aynı parametreleri kullanmaktadır. Bu nedenle istemcilerin aldığı cevaplar tahminin üretilme süresi haricinde aynıdır fakat isteği yapan istemciler farklı istemcilerdir.



```

Microsoft Windows [Version 10.0.17763.557]
(c) 2018 Microsoft Corporation. All rights reserved.

C:\Users\Ceyhun>curl -XGET https://pv-fault-predictor.herokuapp.com/predict/30.101-270.847-8152.8828-524.03-47.88
{
  "G": 524.03,
  "Istr": 270.847,
  "Pstr": 8152.8828,
  "Tc": 49.45,
  "Tm": 47.88,
  "Vstr": 30.101,
  "case0_probability": 0.9832561945324688,
  "case1_probability": 0.008879440039173861,
  "case2_probability": 0.007690200391771205,
  "case3_probability": 0.00017416503658624938,
  "predicted_case": "0",
  "prediction_probability": "0.9832561945324688",
  "run_time": 0.00788199999999995
}


C:\Users\Ceyhun>

```

Şekil 6.44. Test veri setindeki bir örnek için curl aracı ile yapılmış tahmin isteği.

Eğer HTWS Şekil 6.41, Şekil 6.42 ve Şekil 6.43'teki gibi bir hata tahmini yaparsa bu hata bildirimini birkaç saniye içinde önceden belirtilen e-posta adreslerine de gönderebilmektedir. Böylece FV sistem takibinde anlık hata bildirimini de alınabilmektedir. Şekil 6.45'te hata bildirimini için gönderilmiş bir e-posta örneği görülmektedir. Bu bildirim Şekil 6.41'deki hata tahmini yapıldıktan sonra önceden belirtilen adreslere gönderilen e-posta bildirimidir.

HTWS verdiği JSON formatındaki cevap yapısı gereği web, masaüstü, mobil, gömülü sistemler gibi her türde istemci tarafından tahmin isteğinde bulunmak amacıyla kullanılabilir. Bununla birlikte e-posta, SMS gibi anlık hata bildirimleri de gönderebilmektedir.



Şekil 6.45. Hata tahmini için kullanıcılara gönderilen e-posta bildirimi.

7. DEĞERLENDİRME VE SONUÇLAR

FV sistemler, yenilenebilir enerji kaynaklarından erişimi en kolay olan güneş enerjisinin doğrudan elektrik enerjisine çevrilmesini sağlayan sistemlerdir. FV sistem teknolojileri alanındaki yoğun araştırma çalışmaları, bu sistemlerin kurulum maliyetlerini her geçen gün azaltmaktadır. Kurulum maliyetlerinin ve beraberinde amortisman sürelerinin azalması, bu sistemlerin güvenilir bir şekilde izlenmesi gerekliliğini ortadan kaldırmamaktadır. Özellikle FV sistemlerden elde edilecek elektrik enerjisinin olması gerekenden az olması önemli bir sorundur. FV sistemlerin izlenmesi yanında bu sistemlerin doğru bir şekilde analiz edilmesi ve meydana gelen hataların erken teşhisi büyük önem arz etmektedir.

Bu nedenle bugüne kadar FV sistemlerin analizi için pek çok çalışma yapılmıştır. Gelişen teknolojiyle birlikte, FV sistemler için hata tespitinde yapay zekâ tekniklerinin kullanıldığı yöntemler son yıllarda giderek artmaktadır. Fakat artık geleneksel yöntemler denilebilecek bu yöntemler tek bir öğrenme algoritmasından elde edilen modellerin kullanıldığı yöntemlerdir. Bu yöntemlerin en büyük sakıncası, sistemin tahmin kalitesinin kullanılan algoritmanın kendi sınırlarını aşamamasıdır. Bu problemin üstesinden gelmek için kavramsal olarak farklı öğrenme algoritmalarının bir araya getirilmesi ve algoritma çeşitliliğinin getirdiği zenginlik ile tahmin kalitesinin artırılması tercih edilebilir.

Bu amaçla tez çalışması kapsamında son yıllarda pek çok alanda daha sık kullanılmaya başlanan topluluk öğrenmesi yönteminin FV sistemlerde hata tespitinde kullanılması amaçlanmış ve bu amaçla topluluk öğrenmesi temelli özgün bir hata tespit sistemi önerilmiştir. Önerilen hata tespit sisteminin içerdiği topluluk öğrenmesi temelli modelin görevi FV sistemlerdeki hataları sınıflandırmaktır. Çalışmada geliştirilen topluluk modeli, heterojen bir model olup, kavramsal olarak farklı öğrenme algoritmalarının aynı eğitim verileriyle eğitilmesine dayanır. Böylece, aynı çatı altındaki farklı öğrenme algoritmalarının birbirlerinin eksik yönlerini tamamlaması sağlanarak tahmin kalitesinin artırılması amaçlanmıştır.

Topluluk öğrenmesi modelini oluşturacak öğrenme algoritmaları, sınıflandırma problemlerinde yaygın olarak kullanılan algoritmalar

seçilmişlerdir. Bu algoritmalar Gradyan Artırma (Gradient Boosting - GB), İkinci Dereceden Ayrımcı Analiz (Quadratic Discriminant Analysis - QDA), Basit Karar Ağacı (Decision Tree - DT), Rastgele Orman (Random Forest - RF), Ekstra Ağaçlar (Extra Trees - ET) ve Lojistik Regresyon (Logistic Regression - LR) algoritmalarıdır. Bu algoritmalar GB, RF ve ET algoritmaları aynı zamanda yapıları bakımından homojen topluluk modelleridir. Diğerleri ise bireysel algoritmalarıdır.

Topluluk modelini oluşturmadan önce tüm aday öğrenme algoritmalarının ve oluşturulacak son topluluk modelinin eğitiminde kullanılacak olan veri setinin sağlıklı bir şekilde oluşturulması amacıyla veri setinden gereksiz özellikler elenmiştir. Özellik seçimi olarak adlandırılan bu süreç için Scikit-learn makine öğrenmesi kütüphanesinde tanımlı ki-kare test fonksiyonu kullanılmıştır. Bu fonksiyon ile özellik skorları tayin edilmiş, bağıl nem ve hava sıcaklığı gibi diğerlerine göre çok düşük skorlu özellikler elenmiştir. Veri setinde aykırı değer algılama yöntemleri kullanarak aykırı değer içeren örneklerin belirlenmesi ve veri setinden çıkarılması yoluna gidilmemiştir. Çünkü bir FV izleme sisteminde kullanılan elektronik donanımların ve algılayıcıların az ya da çok elektriksel gürültüden etkileneceği kabul edilmiş ve FV sistem bu haliyle analiz edilmiştir.

Aday algoritmalar, özellik seçiminin ardından elde edilen veri seti üzerinde, 10 katlı çapraz doğrulama ile test edilmişlerdir. Algoritmaların testlerde elde ettiği tahmin kalitelerini artırmak amacıyla QDA algoritması haricinde tüm algoritmalar için ayrı ayrı parametre optimizasyonu yapılmıştır. Optimizasyon için Scikit-learn makine öğrenmesi kütüphanesi içerisinde yer alan şebeke-arama fonksiyonu kullanılmıştır. Algoritmalar için en iyi performansı veren parametre seçenekleri kaydedilmiş ve bu parametreler ile yeniden oluşturulan öğrenme algoritmaları tekrar eğitilerek optimize edilmiştir.

Optimize edilmiş aday öğrenme algoritmalarından ikili, üçlü ve dörtlü birleşimler halinde 168 grup oluşturulmuştur. Bu gruplar ile grup içindeki her bir öğrenme algoritmasının eşit ağırlığa diğer bir deyişle eşit oy hakkına sahip olduğu basit aday topluluk modelleri inşa edilmiştir. Bu aday topluluk modelleri 10 katlı çapraz doğrulama ile *f1-skoru* performans ölçütü kullanılarak test edilmiş, en

başarılı ve en başarısız aday topluluk modelleri belirlenmiştir. En başarısız modeller büyük çoğunlukla kendisini oluşturan öğrenme algoritmalarının tahmin kalitelerinin ortalamasından da düşük bir performans sergilemişlerdir. Örneğin en başarısız aday topluluk modelini oluşturan GB ve LR algoritmalarının *f1-skoru* performans ölçütü ile elde edilmiş ortalama tahmin kaliteleri sırasıyla %95,14 ve %93,63 olmuşken, bu iki algoritmadan oluşan aday topluluk modelinin ortalama tahmin kalitesi %93,12'de kalmıştır. Bu değer hem GB ve LR algoritmalarının bireysel tahmin kalitelerinden hem de bunların ortalamalarından küçüktür. Topluluk modelinin iki algoritmadan oluştuğu durumlarda GB ve LR algoritmalarından birinin dâhil olduğu topluluk modelleri çoğunlukla düşük performans sergilemişlerdir.


En başarılı modellerde herhangi bir optimizasyon yapılmadan da topluluk modelinin tahmin kalitesinin, kendisini oluşturan öğrenme algoritmalarının bireysel tahmin kalitelerinin üstüne çıkabildiği tespit edilmiştir. Örneğin en başarılı aday topluluk modelini oluşturan QDA, ET_{gini} ve DT algoritmalarının ortalama tahmin kaliteleri sırasıyla %95,66, %95,97 ve %95,88 olmuşken, bu üç algoritmadan oluşan optimize edilmemiş aday topluluk modelinin ortalama tahmin kalitesi %97,88'e ulaşmıştır. Bu değer hem QDA, ET_{gini} ve DT algoritmalarının bireysel tahmin kalitelerinden hem de bunların ortalamalarından büyüktür.

En başarılı aday topluluk modelini *f1-skoru* performans ölçütü ile elde edilen ortalama tahmin kalitesi yerine hedef sınıfları doğru tahmin etme (sınıflandırma) oranları bakımından incelemek gerekirse QDA, ET_{gini} ve DT algoritmaları, FV dizinin normal çalıştığını sırasıyla %98,77, %99,18 ve %98,77 doğrulukla tahmin edebilmişken bu algoritmalarından oluşan aday topluluk modelinin tahmin doğruluğu %99,59 ile bu algoritmaların üzerine çıkabilmiştir. Bununla birlikte aday topluluk modeli, FV dizideki tek panelin gölgelenmesi hatalarını %80, iki panelin gölgelenmesi ve tek panelin kısa devre olması hatalarını ise %100 tahmin doğruluğuyla tespit ederek bu hata tiplerinde bireysel olarak en yüksek tahmin doğruluğuna ulaşan algoritmalar ile eşit tahmin doğruluğuna ulaşmıştır.

En başarılı aday topluluk modelleri bulunduktan sonra bu modelleri optimize etmek ve içlerinden en iyisini son topluluk modeli olarak belirlemek için farklı

oylama tiplerinde ve farklı oy hakkı ağırlıklarında kapsamlı bir dögüsel arama yapılmıştır. Bu arama işleminde aday algoritmalar farklı ayarlarla 10 katlı çapraz doğrulama yapılarak test edilmiştir. Test sonucunda optimizasyon ile en yüksek başarıyı elde eden model yine QDA, ET_{gini} , DT algoritmalarından oluşan model olmuş ve son topluluk modeli olarak belirlenmiştir. Böylelikle son topluluk modelinin ortalama tahmin kalitesi yapılan optimizasyonun ardından %97,88'den %98,10'a çıkmıştır. Bununla birlikte hedef sınıfları doğru tahmin etme (sınıflandırma) oranları bakımından incelendiğinde tüm normal ve hatalı çalışma durumları için %94,90 olan ortalama tahmin doğruluğu %96,57'ye çıkmıştır.

Şekil 7.1'de QDA, ET_{gini} , DT algoritmaları ile bunların oluşturduğu topluluk modeli (TM) ve optimize edilmiş topluluk modelinin (OTM) hedef sınıflar için elde ettikleri ortalama tahmin doğrulukları görülmektedir. Bu tez kapsamında geliştirilen hata tespit sistemi ve elde edilen sonuçlar bir araştırma makalesi olarak yayınlanmıştır.



Şekil 7.1. Kullanılan modellere ait tahmin doğrulukları ortalamaları.

Sonuç olarak tasarlanan ve ilk örnek üretimi yapılan bulut bağlantılı FV izleme ve hata tespit sisteminin şebekeden bağımsız FV sistemlerde kullanımının uygun olduğu belirlenmiştir. FV sisteme ait elektriksel ölçümler FV dizi ile MPPT özellikli şarj kontrol cihazı arasındaki hatta yapılmaktadır. Şebekeye bağlı bir FV

sisteminde ise aynı ölçümler evirici ile FV dizi arasında yapılabilir, böylelikle FV izleme ve hata tespit sistemi farklı tipteki ve büyüklükteki FV sistemlere de uyarlanabilir. Diğer taraftan, hata tespit yeteneği büyük ölçekli bir FV sisteme uyarlanırken, bu FV sistemden normal ve hatalı çalışma durumlarını içeren etiketlenmiş verilerin tekrar toplanması ve topluluk öğrenmesi modelinin bu yeni eğitim verileriyle tekrar eğitilmesi gereklidir. Ayrıca küçük veya büyük ölçekli her sistemde, topluluk öğrenmesi modelinin eğitiminde kullanılan verilerin uzun yıllara yayılan, farklı iklim koşulları barındıran veriler olması hata tespit sisteminin genelleme yapma yeteneğini arttıracaktır.

Tez çalışması kapsamında geliştirilen deneysel sistemde yer alan FV dizilerde meydana gelen hatalar yüksek dizi güç kayıplarına yol açmaktadır. Bu güç kayıpları yaklaşık olarak, dizideki tek bir panelin gölgelenmesi hatalarında %35, iki panelin gölgelenmesi hatalarında %46, tek panelin kısa devre olması hatalarında ise %48 seviyelerine ulaşabilmektedir. Geliştirilen hata tespit yeteneği, hızlı ve yüksek doğrulukla normal ve hatalı çalışma durumlarını tespit ederek FV sistemin yüksek verimle çalışmaya devam etmesinin sağlanmasında yardımcı olacaktır. Hata tespit yeteneğinin olmadığı bir FV sistemde oluşan hataların manuel olarak tespit edilebilmesi ve ardından hatanın giderilmesi uzun zaman alabileceğinden sistemin uzun süre düşük verimle çalışmasına yol açabilecektir.

Bu tez çalışmasının önceki çalışmalara göre özgün yönleri aşağıdaki maddelerle özetlenebilir:

- FV sistemlerde tek bir öğrenme algoritmasının kullanıldığı geleneksel hata tespit yöntemleri yaygın olarak kullanılmaktadır. Topluluk öğrenmesine dayalı yöntemlerin, FV sistemler dışında farklı alanlarda aykırı değer algılama veya hata tespitinde kullanıldığı sınırlı sayıda çalışma mevcuttur. Özellikle FV sistemlerde hata tespiti için kullanılan bir çalışma mevcut olsa da bu çalışmada kullanılan topluluk öğrenmesi modeli basit karar ağacı temelli homojen bir topluluk modelidir. Bu nedenle, bu tez çalışması kavramsal olarak farklı öğrenme algoritmalarını bir araya getiren heterojen bir topluluk modelinin uygulamaya yönelik kullanılması sebebiyle örnek bir çalışma teşkil etmektedir.

- Tez çalışması kapsamında geliştirilen VYWS ve HTWS sistemleri ile hem izleme sisteminin hem de hata tespit sisteminin bulut katmanında bir arada çalıştırıldığı dünya üzerinde sınırlı sayıda çalışma mevcuttur. Tez çalışması ile ülkemizde bu konuyla ilgili uygulamaya yönelik örnek bir çalışma ortaya çıkmıştır.
- İstemci sunucu mimarisinde geliştirilen FV izleme sistemi ve hata tespit sistemi, her türlü uzak istemciyle haberleşme imkânı sunmaktadır. Haberleşme JSON formatında yapılmaktadır. Bu nedenle FV verileri kaydetme, kaydedilen verileri anlık olarak izleme ya da kaydedilen veriler için anlık olarak hata tahmini isteğinde bulunma amaçlı istemci geliştirmek mümkündür. Bununla birlikte geliştirilecek bir istemci uygulamasının belirli bir programlama diliyle geliştirilme ya da belirli bir işletim sisteminde çalıştırılma kısıtlaması da yoktur. Geliştirilmek istenen bir istemci uygulama, gömülü sistem, web tarayıcı, mobil uygulama ya da masaüstü uygulama temelli olabilir.
- Hata tespit sisteminin, gömülü bir sisteme kurulması, verilerin aktarıldığı bir PC'de çalıştırılması ya da verilerin analizi için herhangi bir harici yazılım kullanılması ihtiyacı yoktur. İşlemci gücü, yazılımların çalıştırılması için bellek ve veri saklama için disk alanı gibi sistem kaynakları bulut bilişim katmanı tarafından sağlandığından sistemin sürdürülebilirliği kolaydır.
- Sistem bütünüyle (front-end ve back-end) özgün olarak tasarlanmıştır, bu nedenle ticari bir ürüne dönüştürülme durumunda ekstra yazılım ve sistem tasarımı maliyeti olmayacaktır. Bununla birlikte, istemci tarafındaki donanımlarda yüksek işlemci gücüne gerek duyulmadığından, nispeten ucuz olmayan geliştirme kartları yerine daha ekonomik mikro denetleyiciler kullanılabilir.
- İstemci tarafındaki yazılım ve donanıma müdahale etmeden, sunucu tarafında bulunan ve hata tespiti yapan topluluk öğrenmesi modeli istenilen doğrultuda değiştirilebilir ve iyileştirilebilir.

Tez çalışmasının devamında, topluluk modelini oluşturan öğrenme algoritmaları çeşitlendirilebilir. Naive Bayes, Destek Vektör Makineleri (Support

Vector Machines - SVM), K-En yakın Komşuluk (K Nearest Neighbors – KNN), Çok Katmanlı Perseptron (Multi-Layer Perceptron - MLP) gibi algoritmalar da eklenerek aday öğrenme algoritması havuzu genişletilebilir.

FV sistemden zaman içerisinde toplanan veriler etiketlenmiş veriler olmayacağından, bu veriler topluluk modelinin eğitilmesinde kullanılamazlar. Bunun üstesinden gelmek ve verileri etiketlemek amacıyla yaygın olarak kullanılan kümeleme yöntemleri ile verilerin etiketlenmesi ve etiketlenmiş verilerin çok katlı çapraz doğrulama ile test edilmek kaydıyla topluluk modelinin tahmin kalitesine olumlu yönde bir katkısının olup olmayacağı araştırılabilir.

Topluluk öğrenmesi temelli modellerin hataları sınıflandırmadaki performansı, makine öğrenmesinin giderek artan bir ilgiyle kullanılmaya başlanan “derin öğrenme” alanındaki çalışmalarla karşılaştırılabilir.

KAYNAKLAR DİZİNİ

- Ahmad, M. W., Mourshed, M., and Rezgui, Y.,** 2018, Tree-based ensemble methods for predicting PV power generation and their comparison with support vector regression. *Energy*, 164, 465–474.
- Akram, M. N., and Lotfifard, S.,** 2015, Modeling and Health Monitoring of DC Side of Photovoltaic Array. *IEEE Transactions on Sustainable Energy*, 6(4), 1245–1253.
- Allen, D. M.,** 1974, The Relationship between Variable Selection and Data Augmentation and a Method for Prediction. *Technometrics*, 16(1), 125.
- Ando, B., Baglio, S., Pistorio, A., Tina, G. M., and Ventura, C.,** 2015, Sentinella: Smart Monitoring of Photovoltaic Systems at Panel Level. *IEEE Transactions on Instrumentation and Measurement*, 64(8), 2188–2199.
- Arab, A. H., Chenlo, F., Mukadam, K., and Balenzategui, J. L.,** 1999, Performance of PV water pumping systems. *Renewable Energy*, 18(2), 191–204.
- Bai, J., Liu, S., Hao, Y., Zhang, Z., Jiang, M., and Zhang, Y.,** 2014, Development of a new compound method to extract the five parameters of PV modules. *Energy Conversion and Management*, 79, 294–303.
- Belghith, O. Ben, and Sbita, L.,** 2014, Remote GSM module monitoring and Photovoltaic System control, 188–192.
- Bonsignore, L., Davarifar, M., Rabhi, A., Tina, G. M., and Elhajjaji, A.,** 2014, Neuro-Fuzzy Fault Detection Method for Photovoltaic Systems. *Energy Procedia*, 62, 431–441.
- Breiman, L.,** 1996, Bagging predictors. *Machine Learning*, 24(2), 123–140.
- Breiman, L.,** 1999, Pasting Small Votes for Classification in Large Databases and On-Line. *Machine Learning*, 36(1/2), 85–103.
- Breiman, L. E. O.,** 2001, Random Forests, 5–32.
- Celik, A. N., and Acikgoz, N.,** 2007, Modelling and experimental verification of the operating current of mono-crystalline photovoltaic modules using four- and five-parameter models. *Applied Energy*, 84(1), 1–15.
- Chao, K., Chen, P.-Y., Wang, M., and Chen, C.,** 2014, An Intelligent Fault Detection Method of a Photovoltaic Module Array Using Wireless Sensor Networks. *International Journal of Distributed Sensor Networks*, 10(5), 540147.
- Chao, K. H., Ho, S. H., and Wang, M. H.,** 2008, Modeling and fault diagnosis of a photovoltaic system. *Electric Power Systems Research*, 78(1), 97–105.
- Chen, Z., Han, F., Wu, L., Yu, J., Cheng, S., Lin, P., and Chen, H.,** 2018, Random forest based intelligent fault diagnosis for PV arrays using array voltage and string currents. *Energy Conversion and Management*, 178(August), 250–264.

KAYNAKLAR DİZİNİ (devam)

- Chin, V. J., Salam, Z., and Ishaque, K.**, 2015, Cell modelling and model parameters estimation techniques for photovoltaic simulator application: A review. *Applied Energy*, 154(September), 500–519.
- Chine, W., Mellit, a., Lughî, V., Malek, a., Sulligoi, G., and Massi Pavan, a.**, 2016, A novel fault diagnosis technique for photovoltaic systems based on artificial neural networks. *Renewable Energy*, 90, 501–512.
- Chouder, A., Silvestre, S., Sadaoui, N., and Rahmani, L.**, 2012, Modeling and simulation of a grid connected PV system based on the evaluation of main PV module parameters. *Simulation Modelling Practice and Theory*, 20(1), 46–58.
- Data science trends., 2019, available at: [https://trends.google.com/trends/explore?date=2016-01-01 2019-03-01&q=Python data science,R data science,Matlab data science](https://trends.google.com/trends/explore?date=2016-01-01%202019-03-01&q=Python%20data%20science,R%20data%20science,Matlab%20data%20science) (Erişim tarihi: 22 Mart 2019)
- De Blas, M. A., Torres, J. L., Prieto, E., and García, A.**, 2002, Selecting a suitable model for characterizing photovoltaic devices. *Renewable Energy*, 25(3), 371–380.
- De Soto, W., Klein, S. A., and Beckman, W. A.**, 2006, Improvement and validation of a model for photovoltaic array performance. *Solar Energy*, 80(1), 78–88.
- Devabhaktuni, V., Alam, M., Shekara Sreenadh Reddy Depuru, S., Green, R. C., Nims, D., and Near, C.**, 2013, Solar energy: Trends and enabling technologies. *Renewable and Sustainable Energy Reviews*, 19, 555–564.
- Dietterich, T. G.**, 2000, Ensemble Methods in Machine Learning. In *Oncogene* (Vol. 12, pp. 1–15).
- Ducange, P., Fazzolari, M., Lazzarini, B., and Marcelloni, F.**, 2011, An intelligent system for detecting faults in photovoltaic fields. *International Conference on Intelligent Systems Design and Applications, ISDA*, 1341–1346.
- Duffie, J., and Beckman, W.**, 2013, *Solar Engineering of Thermal Processes*, 4th ed. *Journal of Solar Energy Engineering* (Vol. 116).
- Düşteğör, D., and Felemban, N. M.**, 2013, Wireless Sensor Network Based Monitoring System for Photovoltaic Panels in Extreme GCC Climate Conditions *, 326–329.
- Geisser, S.**, 1975, The Predictive Sample Reuse Method with Applications. *Journal of the American Statistical Association*, 70(350), 320.
- Geurts, P., Ernst, D., and Wehenkel, L.**, 2006, Extremely randomized trees. *Machine Learning*, 63(1), 3–42.
- Gopal, C., Mohanraj, M., Chandramohan, P., and Chandrasekar, P.**, 2013, Renewable energy source water pumping systems - A literature review. *Renewable and Sustainable Energy Reviews*, 25, 351–370.

KAYNAKLAR DİZİNİ (devam)

- Guerriero, P., D'Alessandro, V., Petrazzuoli, L., Vallone, G., and Daliento, S.,** 2013, Effective real-time performance monitoring and diagnostics of individual panels in PV plants. In 2013 International Conference on Clean Electrical Power (ICCEP) (pp. 14–19). IEEE.
- Harrison, D., and Rubinfeld, D., Boston Dataset. available at: <https://www.cs.toronto.edu/~delve/data/boston/bostonDetail.html> (Erişim tarihi: 12 Mart 2019)
- Hsieh, C.-T., Yau, H.-T., and Shiu, J.,** 2014, Chaos Synchronization Based Novel Real-Time Intelligent Fault Diagnosis for Photovoltaic Systems. *International Journal of Photoenergy*, 2014, 1–9.
- Hu, T., Zheng, M., Tan, J., Zhu, L., and Miao, W.,** 2015, Intelligent photovoltaic monitoring based on solar irradiance big data and wireless sensor networks. *Ad Hoc Networks*, 0, 1–10.
- IEC 61724.,** 1998, Photovoltaic System Performance Monitoring-Guidelines for Measurement, Data Exchange, and Analysis. Switzerland, Geneva.
- Jiang, L. L., and Maskell, D. L.,** 2015, Automatic fault detection and diagnosis for photovoltaic systems using combined artificial neural network and analytical based methods. 2015 International Joint Conference on Neural Networks (IJCNN), 1–8.
- Jones, C. B., Stein, J. S., Gonzalez, S., and King, B. H.,** 2015, Photovoltaic system fault detection and diagnostics using Laterally Primed Adaptive Resonance Theory neural network. 2015 IEEE 42nd Photovoltaic Specialist Conference (PVSC), (1), 1–6.
- Jonke, P., Eder, C., Stockl, J., and Schwark, M.,** 2013, Development of a module integrated photovoltaic monitoring system. *IECON Proceedings (Industrial Electronics Conference)*, 8080–8084.
- JRC Photovoltaic Geographical Information System (PVGIS), available at: http://re.jrc.ec.europa.eu/pvg_tools/en/tools.html#PVP (Erişim tarihi: 15 Mart 2019)
- Karoly, R., and Dumitru, C. D.,** 2015, The Monitoring and Control Processes of a Renewable Energy Management System (Vol. 19, pp. 689–694).
- King, D. L., Boyson, W. E., and Kratochvil, J. A.,** 2004, Photovoltaic array performance model. Sandia Report No. 2004-3535, 8(December), 1–19.
- Kun, X., Sen, M., Xiaobo, D., Linling, Z., and Po, X.,** 2013, Design and Application of the Photovoltaic Inverter Equipment Monitoring System on Android Platform, 1494–1497.
- Lafond, F., Bailey, A. G., Bakker, J. D., Rebois, D., Zadourian, R., McSharry, P., and Farmer, J. D.,** 2018, How well do experience curves predict technological progress? A method for making distributional forecasts. *Technological Forecasting and Social Change*, 128(November 2017), 104–117.

KAYNAKLAR DİZİNİ (devam)

- Li, Y., Lin, P., Zhou, H., Chen, Z., Wu, L., Cheng, S., and Su, F.,** 2018, On-line Monitoring System Based on Open Source Platform for Photovoltaic Array. *Energy Procedia*, 145, 427–433.
- Liu, Y., and Wu, X.,** 2010, A Class of Fuzzy Portfolio Optimization Problems: E-S Models. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (Vol. 6146 LNCS, pp. 43–50).
- Lo Brano, V., Orioli, A., Ciulla, G., and Di Gangi, A.,** 2010, An improved five-parameter model for photovoltaic modules. *Solar Energy Materials and Solar Cells*, 94(8), 1358–1370.
- Louppe, G., and Geurts, P.,** 2012, Ensembles on random patches. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7523 LNAI(PART 1), 346–361.
- Machine learning trends., available at: [https://trends.google.com/trends/explore?date=2016-01-01 2019-03-01&q=Python machine learning,R machine learning,Matlab machine learning](https://trends.google.com/trends/explore?date=2016-01-01%2019-03-01&q=Python%20machine%20learning,R%20machine%20learning,Matlab%20machine%20learning) (Erişim tarihi: 22 Mart 2019)
- Mansour, A. M., Salama, K. N., and Elzahab, E. A.,** 2015, Fault Diagnosis of PV-System in a Smart Grid Using Fuzzy Logic Classifier (pp. 2–7).
- Mekki, H., Mellit, A., and Salhi, H.,** 2016, Artificial neural network-based modelling and fault detection of partial shaded photovoltaic modules. *Simulation Modelling Practice and Theory*, 67, 1–13.
- Myrzik, J. M. A., and Calais, M.,** 2003, String and module integrated inverters for single-phase grid connected photovoltaic systems - A review. 2003 IEEE Bologna PowerTech - Conference Proceedings, 2, 430–437.
- NREL., Best Research-Cell Efficiency Chart. available at: <https://www.nrel.gov/pv/cell-efficiency.html> (Erişim tarihi: 20 Nisan 2019)
- Orioli, A., and Di Gangi, A.,** 2013, A procedure to calculate the five-parameter model of crystalline silicon photovoltaic modules on the basis of the tabular performance data. *Applied Energy*, 102, 1160–1177.
- Papageorgas, P., Piromalis, D., Antonakoglou, K., Vokas, G., Tseles, D., and Arvanitis, K. G.,** 2013, Smart solar panels: In-situ monitoring of photovoltaic panels based on wired and wireless sensor networks. *Energy Procedia*, 36, 535–545.
- Pierro, M., Bucci, F., De Felice, M., Maggioni, E., Moser, D., Perotto, A., Cornaro, C.,** 2016, Multi-Model Ensemble for day ahead prediction of photovoltaic power generation. *Solar Energy*, 134, 132–146.
- Prieto, M. J., Pernía, A. M., Nuño, F., Díaz, J., and Villegas, P. J.,** 2014, Development of a wireless sensor network for individual monitoring of panels in a photovoltaic plant. *Sensors (Switzerland)*, 14(2), 2379–2396.

KAYNAKLAR DİZİNİ (devam)

- Rana, M., Koprinska, I., and Agelidis, V. G.**, 2015, Forecasting solar power generated by grid connected PV systems using ensembles of neural networks. Proceedings of the International Joint Conference on Neural Networks, 2015–Septe, 1–8.
- Renewables 2018 Global Status Report.**, 2018, Retrieved from <http://www.ren21.net/status-of-renewables/global-status-report/>
- Riley, D., and Johnson, J.**, 2012, Photovoltaic prognostics and health management using learning algorithms. Conference Record of the IEEE Photovoltaic Specialists Conference, 1535–1539.
- Ryu, Y., Yoo, J., and Kim, Y.**, 2012, Cloud services based Mobile monitoring for Photovoltaic Systems. 2012 IEEE 4th International Conference on Cloud Computing Technology and Science (CloudCom), 578–580.
- Sampaio, P. G. V., and González, M. O. A.**, 2017, Photovoltaic solar energy: Conceptual framework. Renewable and Sustainable Energy Reviews, 74(June 2016), 590–601
- Shariff, F., Rahim, N. A., and Hew, W. P.**, 2015, Zigbee-based data acquisition system for online monitoring of grid-connected photovoltaic system. Expert Systems with Applications, 42(3), 1730–1742.
- Spataru, S., Sera, D., Kerekes, T., and Teodorescu, R.**, 2015, Diagnostic method for photovoltaic systems based on light I-V measurements. Solar Energy, 119, 29–44.
- Syafaruddin, Karatepe, E., and Hiyama, T.**, 2011, Controlling of artificial neural network for fault diagnosis of photovoltaic array. In 2011 16th International Conference on Intelligent System Applications to Power Systems (pp. 1–6). IEEE.
- T.K.~Ho.** 1998, The Random Subspace Method for Constructing Decision Forests. IEEE Transactions on Pattern Analysis and Machine Intelligence, 20(8), 832–844.
- Tejwani, R., Kumar, G., and Solanki, C.**, 2014, Remote Monitoring for Solar Photovoltaic Systems in Rural Application using GSM Voice Channel. Energy Procedia, 57(1959), 1526–1535.
- Tina, G. M., and Grasso, A. D.**, 2014, Remote monitoring system for stand-alone photovoltaic power plants: The case study of a PV-powered outdoor refrigerator. Energy Conversion and Management, 78, 862–871.
- Vaclav Smil.**, 2017, Energy Transitions: Global and National Perspectives.
- Villalva, M., Gazoli, J., and Filho, E.**, 2009, Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays. IEEE Transactions on Power Electronics, 24(5), 1198–1208.
- Visconti, P., and Cavalera, G.**, 2015, Intelligent System for Monitoring and Control of Photovoltaic Plants and for Optimization of Solar Energy Production.

KAYNAKLAR DİZİNİ (devam)

- Wang, G., Zhao, K., Shi, J., Chen, W., Zhang, H., Yang, X., and Zhao, Y.,** 2017, An iterative approach for modeling photovoltaic modules without implicit equations. *Applied Energy*, 202, 189–198.
- Wang, Z., Wang, Y., and Srinivasan, R. S.,** 2018, A novel ensemble learning approach to support building energy use prediction. *Energy and Buildings*, 159, 109–122.
- Wang, Z. Y., Lu, C., and Zhou, B.,** 2018, Fault diagnosis for rotary machinery with selective ensemble neural networks. *Mechanical Systems and Signal Processing*, 113, 112–130.
- World Bank World Development Indicators.,** 2017, Retrieved from <http://data.worldbank.org/data-catalog/world-development-indicators>
- Woyte, A., Richter, M., Moser, D., Mau, S., Reich, N. H., and Jahn, U.,** 2013, Monitoring of Photovoltaic Systems: Good Practices and Systematic Analyses. 28th European PV Solar Energy Conference and Exhibition.
- Yagi, Y., Kishi, H., Hagihara, R., Tanaka, T., Kozuma, S., Ishida, T., Kiyama, S.,** 2003, Diagnostic technology and an expert system for photovoltaic systems using the learning method. *Solar Energy Materials and Solar Cells*, 75(3–4), 655–663.
- Zhao, Y., Balboni, F., Arnaud, T., Mosesian, J., Ball, R., and Lehman, B.,** 2014, Fault experiments in a commercial-scale PV laboratory and fault detection using local outlier factor. 2014 IEEE 40th Photovoltaic Specialist Conference, PVSC 2014, 3398–3403.
- Zhao, Y., Ball, R., Mosesian, J., de Palma, J.-F., and Lehman, B.,** 2015, Graph-Based Semi-supervised Learning for Fault Detection and Classification in Solar Photovoltaic Arrays. *IEEE Transactions on Power Electronics*, 30(5), 2848–2858.
- Zhao, Y., Yang, L., Lehman, B., de Palma, J.-F., Mosesian, J., and Lyons, R.,** 2012, Decision tree-based fault detection and classification in solar photovoltaic arrays. 2012 Twenty-Seventh Annual IEEE Applied Power Electronics Conference and Exposition (APEC), (December), 93–99.

TEŐEKKÜR

Bu tez alıŐması sűresince desteęini benden esirgemeyen danıŐman hocam sayın Dr. Őęr. Őyesi Mete ubuku'ya, tez izleme komitesi űyeleri Dr. Őęr. Őyesi Mustafa Engin'e ve Dr. Őęr. Őyesi Osman Őzkaraca'ya teŐekkűr ederim.

Sabırla hep bana destek olan sevgili eŐim Nurcan'a, neŐe kaynaęım, oęlum Balamir'e, maddi manevi destekleriyle her zaman yanımda olan annem, babam ve kardeŐlerime teŐekkűrű bir bor bilirim.

Ceyhun KAPUCU, 2019



ÖZGEÇMİŞ

Adı Soyadı: Ceyhun Kapucu

Uyruk: T.C.

Doğum Tarihi – Yeri: 04.10.1976 – Osmaniye

Telefon: 0 533 435 5930

E-posta Adresi: ckapucu@gmail.com

Akademik Geçmişi:

Öğretim Görevlisi: 2004 yılında Muğla Üniversitesi Enformatik Bölümünde göreve başlamıştır. Halen bu görevine devam etmektedir.

Doktora: Ege Üniversitesi, Güneş Enerjisi Enstitüsü (2019)

Yüksek Lisans: Muğla Üniversitesi, Teknik Eğitim Fakültesi (2006)

Lisans: Muğla Üniversitesi, Fen-Edebiyat Fakültesi, İstatistik ve Bilgisayar Bilimleri (2000)

EKLER

Ek 1 Tezde kullanılan bazı cihazlara ait teknik özellikler.



Ek 1 Tezde kullanılan bazı cihazlara ait teknik özellikler.

(a) MPPT özellikli bir şarj kontrol cihazı:

- Akü gerilimi: 12/24V otomatik seçim
- Maksimum akü akımı: 15A
- Maksimum FV gücü: 200W (12V akü), 400W (24V akü)
- MPPT gerilim aralığı: 15V-70V (12V akü), 30V-70V (24V akü)
- Maksimum verim: %98
- İç sarfiyat: 10mA
- MPPT algoritması

(b) Piranometre:

- Doğruluk: $\pm\%4$ (45° zenith açısı)
- Çıkış: 200mV/Wm⁻², 220mV @ 1100W/m²
- Hassasiyet: 5Wm⁻²/mV
- Çalışma ortamı: -40°C / 55°C
- Giriş gücü: Kendinden beslemeli