

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



**FOTOVOLTAİK SİSTEMİN ÇIKIŞ GÜCÜNÜN
UÇ ÖĞRENME ALGORİTMASI İLE TAHMİNİ**

Serhat TOPRAK

**Yüksek Lisans Tezi
Anabilim Dalı: Enerji Sistemleri Mühendisliği
Programı: Yenilenebilir Enerji
Danışman: Doç. Dr. Resul ÇÖTELİ**

TEMMUZ-2019

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FOTOVOLTAİK SİSTEMİN ÇIKIŞ GÜCÜNÜN UÇ ÖĞRENME ALGORİTMASI İLE
TAHMİNİ

YÜKSEK LİSANS TEZİ

Serhat TOPRAK

(122135105)

Tezin Enstitüye Verildiği Tarih : 26 Haziran 2019
Tezin Savunulduğu Tarih : 26 Temmuz 2019

Tez Danışmanı : Doç. Dr. Resul ÇÖTELİ (F.Ü) 
Diğer Jüri Üyeleri : Prof. Dr. Sami EKİCİ (F.Ü) 
Dr. Öğr. Üyesi Mehmet ÜSTÜNDAĞ (B.Ü) 

TEMMUZ-2019

ÖNSÖZ

Gelişen dünyada, dünya nüfusunun artması, günümüzde toplumun ihtiyaçlarının değişmesi, buna nazaran sanayi ve teknolojinin gelişmesiyle enerjiye duyulan gereksinim giderek artmaya devam etmektedir. Günümüzde daha çok kullanılan fosil yakıtlı enerji üretim sistemleri dünyadaki enerji tüketim talebini karşılamaktadır. Ancak mevcut rezervlerin bir gün tükeneceği düşünülerek araştırmacılar, var olan enerji kaynaklarının yanı sıra tükenmeyen ve çevreye daha az zarar veren alternatif enerji kaynaklarının bulunmasına, etkin bir şekilde kullanılması çalışmalarına yönelmiştir. Yenilenebilir enerji kaynakları arasında en yaygın faydalanılan ise güneş enerjisidir.

Bu tez çalışması süresince, desteğini esirgemeyen danışman hocam, Sayın Doç. Dr. Resul ÇÖTELİ'ye, verilerin alınmasında yardımcı olan Prof. Dr. Hikmet ESEN'e çok teşekkür ederim.

Yine çalışma boyunca, gösterdikleri sabır ve desteklerinden dolayı aileme teşekkür eder, şükranlarımı sunarım.

Serhat TOPRAK
ELAZIĞ-2019

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET	IV
SUMMARY	V
ŞEKİLLER LİSTESİ	VI
SEMBOLLER LİSTESİ	IX
KISALTMALAR.....	X
1. GİRİŞ.....	1
1.1. Literatür çalışması	6
1.2. Tezin Amacı	9
2. PV SİSTEMLER	12
2.1. PV Hücresinin I-V Eğrisinden Maksimum Güç Noktasının Tespiti.....	20
2.2. Güneş Pillerinde Dolgu Faktörü ve Verim	21
2.3. Sıcaklığın PV Hücreye Etkisi	23
2.4. Işınımın PV Hücreye Etkisi	24
2.5. Şebeke Bağlantısına Göre PV Sistemler	24
2.5.1. Şebekeden Bağımsız PV Sistemler	25
2.5.2. Şebekeye Bağlı PV Sistemleri.....	26
2.6. Türkiye'nin Güneş Enerjisi Potansiyeli.....	27
3. MAKSİMUM GÜÇ NOKTASI İZLEME.....	30
3.1. Maksimum Güç Noktası İzleme İçin Algoritmalar	31
3.1.1. Değiştir - Gözle Yöntemi	32
3.1.2. Artan İletkenlik Yöntemi.....	34
3.1.3. Sabit Gerilim Yöntemi	37
3.1.4. Sabit Akım Yöntemi.....	38
3.1.5. Bulanık Mantık Denetim Yöntemi	39
3.1.6. Geleneksel MPPT Algoritmalarını İçeren Çalışmalar.....	42
4. UÇ ÖĞRENME MAKİNESİ.....	44
4.1. Eğim Tabanlı Öğrenme Algoritmaları	47
5. DENEYSEL ÇALIŞMA.....	52
6. SONUÇLAR.....	64
KAYNAKLAR.....	66
ÖZGEÇMİŞ	75

ÖZET

Bu tez çalışmasında, farklı çalışma şartları altında bir PV panelin çıkış gücü uç öğrenme algoritması (UÖA) yardımı ile tahmin edilmeye çalışılmıştır. Bu amaçla, 180 W gücünde bir PV panel kurulmuş, bu panelin açık devre gerilimi, kısa devre akımı, panel sıcaklığı ve güneş ışınımı belirli aralıklarla ölçülerek kaydedilmiştir. Toplam 75 adet deneysel veri elde edilmiştir. Açık devre gerilimi ve kısa devre akımından panelin maksimum gücü hesaplanmıştır. UÖM kullanılarak oluşturulan PV panelin regresyon modeline giriş olarak panel sıcaklığı ve güneş ışınımı verilirken, regresyon modelinin çıkışı PV panelin maksimum gücü olarak alınmıştır. UÖA'nın bazı parametreleri (giriş nöron sayısı, aktivasyon fonksiyonu) deneme yanılma yöntemi ile en iyi sonucu verecek şekilde ayarlanmıştır. Oluşturulan veri kümesi eğitim ve test kümeleri olarak ayrılmıştır. Yöntemin başarımı 5-katlamalı çapraz doğrulama yöntemi ile incelenmiştir. Bu amaçla, veri kümesi 5 eşit parçaya bölünmüştür. Bu parçalardan biri test için ayrılıp geri kalan dördü ağın eğitimi için kullanılır ve bu işlem her defasında test kümesi değiştirilerek gerçekleştirilir. Toplamda 5 defa ağ farklı kümelerle eğitilip test edilmiş olur. Ağın test sonucunda, bütün test fonksiyonlarının performanslarının toplamının ortalaması alınır. UÖA algoritması MATLAB yazılımı kullanılarak gerçekleştirilmiştir. Ayrıca PV panelin çıkış gücünün tahmini için farklı regresyon modelleri de kullanılmış ve bu modellerden elde edilen sonuçlar UÖM'nin sonuçları ile karşılaştırılmıştır. Elde edilen regresyon sonuçlarından, UÖM'nin PV panelin çıkış gücünü çok yüksek doğrulukta tahmin ettiği görülmüştür. Ayrıca UÖM'nin eğitim süresinin diğer regresyon modellerine göre daha kısa ve eğitim algoritmasının çok basit olması gibi üstünlükleri UÖM'yi PV panellerin çıkış gücünün tahmininde etkin bir araç olarak kullanılabileceğini göstermiştir.

Anahtar Kelimeler: UÖM, Matlab, PV, YSA, MPPT, Güneş Pili

SUMMARY

The Estimation of Output Power of A Photovoltaic System by Extreme Learning Machine

In this thesis, the output power of a PV panel under different operating conditions is estimated via extreme learning machine (ELM). For this purpose, PV panel of 180 W was installed and the open circuit voltage, short circuit current, panel temperature and solar radiation were measured and recorded at regular intervals. 75 experimental data were obtained. The maximum power of the panel is calculated from the open circuit voltage and short circuit current. While the panel temperature and solar radiation are given as input to the regression model of the PV panel formed using ELM, the output of the regression model is taken as the maximum power of the PV panel. Some parameters of ELM such as number of input neurons, activation function were adjusted to provide the best results by trial and error method. The obtained data set is divided into training and test sets. The performance of the method was examined by 5-fold cross-validation method. For this purpose, the data set is divided into 5 equal parts. For this purpose, the data set is divided into 5 equal parts. One of these parts is reserved for testing and the remaining four are used for training the network, and this is done by changing the test set each time. One of these parts is reserved for testing and the remaining four are used for training the network, and this is done by changing the test set each time. A total of 5 times the network is trained and tested with different clusters. The test result of the network is averaged over the sum of the performances of all test functions. The ELM algorithm was implemented using MATLAB software. In addition, different regression models were used to estimate the output power of the PV panel and the results obtained from these models were compared with the results of the ELM. According to the regression results, it is seen that ELM estimates the output power of PV panel with very high accuracy. According to the regression results, it is seen that ELM estimates the output power of PV panel with very high accuracy. In addition, the advantages of ELM as shorter training time compared to other regression models and the fact that the training algorithm is very simple showed that ELM could be used as an effective tool in estimating the output power of PV panels.

Key Words: ELM, Matlab, PV, ANN, MPPT, Solar Cell

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1. Güneş pilinin iç yapısı.....	14
Şekil 2.2. Güneş pili temel elektriksel modeli.....	14
Şekil 2.3. Omik bir yükü besleyen bir güneş pili için basitleştirilmiş tek diyot eşdeğer Devresi.....	15
Şekil 2.4. Sabit sıcaklıkta (25°C), değişken ışınímda ($1000 - 200 \frac{W}{m^2}$) bir PV panelin çalışma noktası ve elektriksel yükü; a) $1000 \frac{W}{m^2}$ sabit ışınímda, 25°C – 75°C değişen sıcaklıkta, b) $1000 - 200 \frac{W}{m^2}$ değişken ışınímda, 25°C sabit sıcaklıkta.....	16
Şekil 2.5. (a) PV hücreleri, PV modülleri ve PV dizileri (b) Kristalli bir silikon güneş pilinin yapısı	17
Şekil 2.6. PV hücre, modül, panel ve dizi	18
Şekil 2.7. Işıním ile kısa devre akımı ve açık devre geriliminin ilişkisi	19
Şekil 2.8. Belirli bir sıcaklıkta ve güneş ışınímında bir güneş pilinin I-V ve P-V eğrisi 20	
Şekil 2.9. İdeal bir PV hücrenin I-V ve P-V karakteristikleri	21
Şekil 2.10. Bir PV hücrenin dolgu faktörünü gösteren karakteristik I-V eğrisi.....	22
Şekil 2.11. Bir PV modül için sabit ışıním şartlarında sıcaklığın I-V ve P-V karakteristikleri üzerine etkileri.....	23
Şekil 2.12. Bir PV modül için sabit sıcaklıkta ışınímın I-V ve P-V karakteristikleri üzerine etkileri	24
Şekil 2.13. Şebekeden bağımsız PV sistemi	25
Şekil 2.14. Hibrit bir PV sisteminin blok şeması	26
Şekil 2.15. Şebekeye bağı PV sistemlerinin blok şeması [49]: (a) Dağıtılmış şebekeye bağı PV sistemleri, (b) Merkezi şebekeye bağı PV sistemleri	26
Şekil 2.16. Türkiye'nin güneş radyasyon haritası ve aylara göre güneşlenme süreleri ..	29
Şekil 3.1. MPPT kontrollü bir PV sistemin blok diyagramı	31
Şekil 3.2. P_{PV} - V_{PV} karakteristiğinde çalışma bölgeleri	33
Şekil 3.3. Değiştir&Gözle (D&G) algoritması akış diyagramı	34
Şekil 3.4. Artan İletkenlik algoritması çalışma eğrisi	35
Şekil 3.5. Artan iletkenlik algoritması akış diyagramı.....	36
Şekil 3.6. Sabit gerilim metodu akış diyagramı	38
Şekil 3.7. Bulanık Mantık Denetimi Blok diyagramı.....	39

Şekil 3.8. (a)Hata (E) girişi için üyelik fonksiyonu, (b)Hatadaki değişim (CE) girişi için üyelik fonksiyonu, (c) Görev oranı, (D) çıkışı için üyelik fonksiyonu ..	41
Şekil 5.1. Gerçek güç değerleri ve tanjant sigmoid aktivasyon fonksiyonu kullanan UÖM'nin tahmin ettiği güç değerleri	53
Şekil 5.2. Tanjant sigmoid aktivasyon fonksiyonu kullanan UÖM'nin gizli katman hücre sayısı 10 ve 20 için regresyon eğrileri.....	54
Şekil 5.3. Gerçek güç değerleri ve radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin tahmin ettiği güç değerleri	55
Şekil 5.4. Radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin gizli katman hücre sayısı 10 ve 20 için regresyon eğrileri.....	56
Şekil 5.5. Gerçek güç değerleri ve radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin tahmin ettiği güç değerleri	57
Şekil 5.6. Üçgen aktivasyon fonksiyonu kullanan UÖM'nin gizli katman hücre sayısı 10 ve 20 için regresyon eğrileri.....	58
Şekil 5.7. Farklı regresyon modellerinden elde edilen tahmin sonuçları	62

TABLÖLAR LİSTESİ

Sayfa No

Tablo 2.1. Türkiye ‘nin toplam güneş enerjisi potansiyelinin aylara göre dağılımı	28
Tablo 2.2. Türkiye’nin yıllık toplam güneş enerjisi potansiyelinin bölgelere göre dağılımı.....	28
Tablo 3.1. Bulanık Mantık Denetimi İçin Kural Tabanı.....	42
Tablo 5.1. Gizli katman hücre sayısının (GKHS) farklı değerleri ve farklı aktivasyon tipleri için UÖM’den elde edilen RMSE ve eğitim süreleri.....	59
Tablo 5.2. Regresyon modelleri için performans parametreleri	63

SEMBOLLER LİSTESİ

I_L	: Hücre çıkış akımı
I_D	: Diyot akımı
k	: Boltzman sabiti
q	: Birim elektron yük miktarı
T	: Kelvin cinsinden hücrenin mutlak sıcaklığı
R_s	: Seri direnç
R_{sh}	: Şönt direnç
I_L	: Foto-akımı
V_{mpp}	: Maksimum gerilim
I_{mpp}	: Maksimum akım
P_{mpp}	: Maksimum güç
V_{oc}	: Açık devre gerilimi
I_{sc}	: Kısa devre akımı
k_v	: Gerilim sabiti
k_i	: Akım sabiti
FF	: Dolgu faktörü
I_{mpp}	: Maksimum akım
P_{in}	: Optik giriş gücü
η	: Güneş pilinin verimi
$E(k)$	: Hata
$C(k)$	: Hata değişim fonksiyonu

KISALTMALAR

ARIMA	: Otomatik Regresif Entegre Hareketli Ortalama
CPV	: Konsantre PV
CSP	: Konsantre Güneş Enerjisi
DDVM	: Doğrusal destek vektör makineleri
DLRM	: Dayanıklı lineer regresyon modeli
DOE	: ABD Enerji Departmanı-Department of Energy
GEPA	: Türkiye'nin Güneş Enerjisi Potansiyeli Atlası
GES	: Güneş enerji santralleri
GKHS	: Gizli katman hücre sayısı
ISC	: Kısa devre akımı
KDVM	: Kuadratik destek vektör makineleri
LRM	: Lineer regresyon modeli
MAE	: Ortalama mutlak hata
MPP	: Maksimum güç noktası
MPPT	: Maksimum Güç Noktası İzleme
MSE	: Ortalama karesel hata
RKGRM	: Rasyonel kuadratik Gauss regresyon modeli
RMSE	: Kök kare ortalama hata
SLFN	: Tek gizli katmanlı sinir ağı
UÖA	: Uç Öğrenme Algoritması
UÖM	: Uç Öğrenme Makinesi
ÜGRM	: Üstel Gauss regresyon modeli
VOC	: Açık devre gerilimi
WMO	: Dünya Meteoroloji Örgütü

1. GİRİŞ

Ülkemizde ve dünyada elektrik enerjisine olan ihtiyaç sürekli artmaktadır. Artan bu ihtiyacı karşılamak için kullanılan fosil yakıt kaynakları ise hızla tükenmektedir. Ayrıca fosil yakıt kullanımının olumsuz etkilerinden dolayı, dünyamızda ortam sıcaklıkları yükselmekte, buzullar erimekte ve doğal felaketler meydana gelmektedir. Bu nedenlerden dolayı, çevre sorunlarına sebep olmayan, temiz, güvenilir ve sürdürülebilir nitelikteki yenilenebilir enerjiler, insanoğlunun geleceği için büyük önem taşımaktadır. Bu enerji üretimleri, birincil enerjilerin temini için diğer ülkelere olan bağımlılığın da ortadan kaldırılmasında önemli bir rol oynamaktadır. PV tabanlı elektrik üretiminin artması, geleneksel fosil yakıt tabanlı teknolojilere kıyasla çevre için avantajlar sağlamaktadır [1].

Yenilenebilir enerji kaynakları, çevre dostu elektrik üretiminde önemli bir role sahiptirler. Güneş enerjisi de yenilenebilir enerji kaynaklarından biridir. Güneş, enerjisini tüm yönlerde homojen bir şekilde ışıma yolu ile yayar [2]. Güneş dünya için ısı ve enerji kaynağıdır. Yeryüzündeki güneş enerjisi çıkışına güç yoğunluğu denir. Dünya üzerinde güneş ışıınının güç yoğunluğu $1.4 \text{ kW}/\text{m}^2$ 'dir. Bu değer yıl boyunca değişmesine rağmen bu değişim % 0.1'den fazla değildir. Bu değişimin bir nedeni, dünya ve güneş arasındaki mesafesinin değişmesidir. Bu mesafe bir yıldan diğerine değişir, bu da güç yoğunluğunun $1.308 \text{ kW}/\text{m}^2$ ile $1.398 \text{ kW}/\text{m}^2$ arasında değişmesine neden olur. Güneşin yaydığı ışıma gücü, yaklaşık $4.7 \times 10^{25} \text{ W}$ 'tır.

Güneş enerjisi, güneşin çekirdeğinde meydana gelen füzyon işlemi ile açığa çıkar. Füzyon işleminde hidrojenin helyuma dönüştürülür. Bu işlem esnasında saniyede 4×10^6 ton kütle enerjiye dönüşerek yaklaşık $386 \times 10^6 \text{ EJ}$ (ekstra joule) değerindeki enerji ışıının şeklinde uzaya yayılır. Füzyon işleminin milyonlarca yıl daha devam edeceği düşünülürse güneş, gezegenimiz için sonsuz bir enerji kaynağıdır. Atmosfere gelen güneş ışıınının yaklaşık % 17.5'i atmosferi ısıtmak için kullanılırken yaklaşık % 35'i bulutlardan ve yerden yansıyarak tekrar uzaya geri dönmektedir. Geriye kalan % 47.5 değerindeki miktar ise yeryüzüne düşmektedir ve ısıya dönüşmektedir. Dünya atmosferinin dışında güneş enerjisinin değeri $1370 \text{ W}/\text{m}^2$ kadardır. Buna karşılık, yeryüzüne ulaşan miktarı atmosferden dolayı sadece $0 - 1100 \text{ W}/\text{m}^2$ değerleri arasındadır [1].

Güneş ışınlamını doğrudan elektrik enerjisine dönüştüren sistemlere fotovoltaik sistemler (PV) denir. Bu sistemlerin diğer geleneksel enerji santrallerine kıyasla, çevre dostu olmaları, kömür veya gaz gibi yakıt maliyetlerinin olmaması, düşük işletme ve bakım maliyetlerinin olması ve PV modülleri geri dönüştürülebilir olması gibi birçok avantajı vardır.

PV sistemin gücünü belirleyebilmek için, mevcut güneş ışınlam miktarının ne kadar olduğunu bilmek gerekir. Güneş ışınlamı, Güneş'in yaydığı ışık, ısı ve her türlü elektromanyetik dalgalarıdır. Güneş ışınlamı, bir güç yoğunluğu (W/m^2) olarak ifade edilir. Güneş ışınlamı değişkendir ve dolayısıyla elektrik enerjisi üretim istikrarını sağlamak için güneş enerjisi miktarını tahmin etmek çok önemlidir. Güneş ışınlamının, alınan güneş ışınlamı hesaplanırken dikkate alınması gereken üç önemli temel bileşeni vardır. Dünya Meteoroloji Örgütü (WMO), kullanılan bileşenlere ek olarak bu bileşenlerin nasıl ölçüleceğine dair ayrıntılı talimatlar sunmaktadır. Doğrudan normal ışınlam şiddeti, yatay toprak yüzeyinde herhangi bir atmosferik kayıp olmaksızın güneşten gelen doğrudan bir yoldan alınan güneş radyasyonunun azalan miktarıdır. Bu radyasyon miktarı, Konsantre Güneş Enerjisi (CSP) ve Konsantre PV (CPV) sistemler gibi yoğunlaşan güneş termik tesisatları için çok önemli bir bileşendir. Yaygın yatay ışıma oranı, hava molekülleri, bulut veya diğer parçacıklar tarafından dağınık olduğundan güneşten gelen dolaylı bir yolla yatay toprak yüzeyinde alınan azalan güneş radyasyonunun miktarıdır. Küresel Yatay Işınlam, yüzey tarafından yere yatay olarak alınan toplam radyasyon miktarıdır. Hem doğrudan normal ışınlam hem de difüzyon yatay ışınlamı içerir [3].

Dünyada şebeke bağlantılı sistemlerin ülkelere dağılımında, Çin 78 GW'ı aşan kurulu gücü ile birinci sıradadır. Çin'i sırasıyla Japonya, Almanya, ABD, İtalya, Birleşik Krallık ve Hindistan takip etmektedir. Ülkemiz ise 2018 yılı itibarı ile 12. sıradadır. Almanya, 3.3 GW kurulum ile Avrupa'nın en büyük PV pazarına sahiptir [4]. Ayrıca konutların elektrik ihtiyacı için PV kurulumlarında büyük bir artış görülmektedir [5]. Türkiye'de 2016 yılı sonu itibarıyla kurulu gücü 402 MW olan 34 adet güneş enerjisi santraline ön lisans, kurulu gücü 12.9 MW olan 2 adet güneş enerjisi santraline lisans verilmiştir. Lisanssız elektrik üretim santrallerinin kurulmasıyla birlikte 2016 yılı sonu itibarıyla güneş enerjili santral sayısı 1.043 olarak görülürken bu santrallerin kurulu gücü ise 819.6 MW olup 2 adet lisanslı güneş enerjisi santrali ile birlikte toplam kurulu gücümüz 832.5 MW'a ulaşmıştır.

Güneş enerjisinin birincil enerji kaynağı haline gelmemesinin bazı nedenleri vardır. Bu nedenler arasında en önemlileri PV panellerin yüksek maliyeti ve düşük verimleridir. PV paneller yarı iletken malzemelerden üretilmektedir. Konvansiyonel güç kaynakları, PV

panellerin maliyetini düşürmek için on yıllar boyunca farklı gelişmelere uğramıştır. Son yıllarda, PV modül fiyatında % 60'lık bir azalma meydana gelmiştir. 2020 yılında PV modül maliyetinde % 40'dan fazla azalma gerçekleşeceği öngörülmektedir [6]. Pek çok ülke, PV panel üretiminin maliyetini düşürmeye yardımcı olmak için teşvikler sunmaktadırlar. Bu durumun ana hedefi, yenilenebilir enerji kaynaklarının hızla gelişmesini sağlayacak ve sonuç olarak daha düşük teknoloji maliyetleriyle sonuçlanacak yenilenebilir enerji kaynakları için sağlam bir pazar oluşturmaktır [7]. Böylece PV yatırımcılara ve müşterilere daha cazip hale gelecek ve daha temiz enerji üretimi sağlanacaktır. Aynı zamanda sera gazı emisyonları da azalacaktır [8].

Güneş enerjisi çevre dostu bir enerji kaynağıdır. Ancak, bulutlar ve hava koşulları güneş enerjisinin kullanılabilirliğini etkileyebilir. Bu nedenle güneş enerjisinden üretilen elektrik enerjisi farklı parametrelere bağlı olarak değişken olabilir. Bu nedenlerle dolayı güneş santralleri ile yük talebine cevap vermek çok zor bir görevdir. Bu durumu önlemenin bir yolu PV sistemlerin çıkış gücünü tahmin etmektir [9-10]. Güneş enerjisini tahmin etmek için farklı tahmin yöntemleri kullanılabilir. Bu tahmin, enerji santrali operatörlerinin güneş enerjisi koşullarını izlemelerine ve güç çıkışında herhangi bir hızlı dalgalanmaya hazır hale gelmesine yardımcı olacaktır. Ayrıca, enerji depolama sistemleri, güneş enerjisindeki değişimler ile uğraşmada yardımcı olabilecek olası çözümlerden biri olarak düşünülebilir. Bunun yanında enerji depolama sistemleri sisteme hem yüksek bir maliyet ve hem de bakım masrafı getirmektedir.

Mevcut elektrik şebekeleri uzun zaman önce kurulmuştur. Bu şebekelerin yenilenebilir enerji kaynaklarına uyumlu hale getirilmesi ve modernize edilmesi gerekmektedir.

ABD Enerji Departmanı (Department of Energy - DOE) SunShot programı aracılığıyla yenilenebilir enerji kaynaklarının farklı yönlerini desteklemekte ve finanse etmektedir. Sistem entegrasyonu, DOE'nin tüm destek ve finansmanı sağlamak için izlediği zorluklardan biridir. Bu tür bir destek; güvenli, düşük maliyetli bir şekilde güneşten elektrik enerjisi üretimini artırmaya yardımcı olur [11]. Güneşin değişkenliği de güneş enerji santrallerinin şebeke ile bütünleşmesini etkileyen bir sorundur. Daha önceden belirtildiği gibi tahmin ve enerji depolama sistemleri güneş entegrasyonunun güvenilirliğini artırmaya yardımcı olacak potansiyel çözümlerdir.

Şebeke performansı ve güvenilirlik, iletişim ve güç elektroniği gibi diğer zorluklar farklı yönlerden ele alınabilir. Güneş enerjisi entegrasyonu, mevcut şebeke ile katlanarak arttığından, güç elektroniği bu entegrasyonu daha güvenilir hale getirmek için önemli bir rol

oynamıştır [12]. Son yıllarda ülkemizde büyük ölçekli yenilenebilir enerji santrallerinin sayısında belirgin bir artış yaşanmıştır. Petrol fiyatındaki değişimler ve küresel ısınma, yenilenebilir enerji kaynaklarının kullanımını hızlandırmıştır. Yenilenebilir kaynakların değişkenliği bu kaynaklardan üretilen elektriğin şebeke ile entegrasyonunda önemli bir problemdir [13]. Değişkenlik ve belirsizlik yenilenebilir kaynakların özünde bulunan özelliklerdir. Tahmin, güneş enerjisi üretiminin belirsizliğini azaltmayı ve böylece güç operatörünün değişkenliğini karşılamayı hedeflemektedir [10].

Güneş ışıınımı tahmin edilebilirse, PV sistemlerin çıkış gücü de yaklaşık olarak tahmin edilebilir. Güneş ışıınımı ve hava koşulları gibi birçok faktör PV sisteminin çıkış gücünü etkileyebilir. Bu nedenle, PV sisteminin şebekeye güvenilir bir şekilde entegrasyonunu sağlamak için PV çıkışındaki ani güç değişiklikleri meydana gelebilir. Güneş tahmini, farklı zaman aralıkları için yapılabilir. Kısa süreli tahmin, bir saatten birkaç saate kadar, orta süreli tahmin birkaç saatten bir haftaya kadar, uzun süreli tahmin ise bir haftadan birkaç yıla kadar olan süreyi kapsar.

Tahmin sadece güneş ve rüzgâr gibi değişken yenilenebilir enerji kaynakları için gerekli değildir. Ayrıca, yük tahmini için de yararlıdır. Buna ek olarak, elektrik fiyatı gibi enerji ekonomisi için de yapılabilir. Tahmin, kontrol, birim taahhüdü, güvenlik değerlendirmesi, planlama ve şebeke entegrasyonu gibi farklı alanlarda güç sistemine yardımcı olur [14]. Değişken üretim tahmini yapılması durumunda elde edilebilecek bazı olumlu sonuçlar aşağıda sıralanmıştır [15]:

- Üretilen gücün dengesizliğinden dolayı cezaları ve masrafları en aza indirmek,
- Gerçek zamanlı ve gün öncesi enerji piyasası hakkında iyi bilgi sahibi olmak,
- Güvenilir işletme ve bakım planlamasına yardımcı olmaktır.

Yenilenebilir enerji kaynaklarının sürekli olmaması, enerji üretim maliyetinin dengesizliğine neden olmaktadır. Bununla birlikte, güç tahmini, bu maliyetlerin azalmasına yardımcı olur. Ayrıca tahmin yapılarak bu değişmelerin zamanı ve büyüklüğü belirlenerek işletme maliyeti düşürülür ve güç operatörlerinin bu değişmeler için farklı çözümler bulması sağlanır. Daha önce de belirtildiği gibi, güneş ışıınımının tahmini, PV tesislerinin elektrik şebekesine entegre edilmesi açısından önemlidir. Düşük hata ile güneş ışıınımının tahmini, güç sistemi operatörlerinin güç üretimlerini optimize etmelerine ve üretimdeki sapmaların üstesinden gelmek için uygun bir strateji hazırlanmasına yardımcı olur [15,16].

Güneş enerji santrallerinden (GES) elektrik üretimi iki yolla yapılabilir. Bunlardan birincisi güneş ışıınımından doğrudan elektrik enerjisinin üretildiği fotovoltaik (PV)

sistemler ve diğeri ise güneşin ısı etkisi kullanılarak elektrik enerjisinin üretildiği termal sistemlerdir. PV sistemlerde, güneş ışınımı PV paneller yardımı ile doğrudan elektrik enerjisine dönüştürülmekte ve elde edilen enerji bir inverter yardımı ile AC gerilime dönüştürülür. Termal sistemlerde ise özel aynalar kullanılarak güneş ışınları belli bir noktaya yoğunlaştırılmaktadır. Bu noktada bulunan sıvı ısıtılarak sıvı ile termik sistemlerde olduğu gibi buhar basıncı vasıtası ile mekanik enerji kinetik enerjiye dönüştürülmektedir. Elde edilen kinetik enerji kullanılarak da elektrik enerjisi üretilmektedir.

PV modüllerin fiyatı son yıllarda sürekli düşmektedir [17]. İnverter ve PV sistemlerin kurulumunda kullanılan diğer ekipmanların maliyetlerinin de modül maliyetleri kadar hızlı düşmese de, PV sistemlerinden elektrik üretmenin toplam maliyetinin düşmesi beklenmektedir [18]. Fiyattaki bu düşüş daha fazla yatırımcıyı GES kurmaya teşvik edecektir. Araştırma durumundaki PV hücrelerinin verimlilik iyileştirme oranı nispeten yavaş olmakla birlikte, ticari modüllerin verimliliğinin artması beklenmektedir: Örneğin, tipik ticari düz levha modüllerinin verimliliği, 2010'da % 16'dan 2050'de % 40'a çıkması beklenmektedir [18]. Bilinen en iyi hücre verimliliği, laboratuvar ortamında üç jonksiyonlu PV hücreleri için % 37.70'dir [19]. PV hücrelerin veya modüllerin verimliliğinin artması, hem PV kurulumu için gerekli alanın azalmasına ve dolayısıyla toplam tesis maliyetlerinin düşmesine yardımcı olacaktır.

Bununla birlikte, PV sistemlerden elde edilen güç, solar radyasyon, gölgelenme ve panel kirliliği gibi nedenlerden dolayı değişkenlik göstermektedir. Değişkenliğin üstesinden gelmeye yönelik bir yaklaşım, PV çıkış gücünün tahmin edilmesidir. Bu tür öngörüler kullanılarak, şebeke bağlantısız PV kullanıcıların enerji depolama sistemlerinin kapasitesi optimize edilebilir [20]. Benzer şekilde, şebekeye bağlı dağıtılmış PV kullanıcıları enerji kullanım programları en uygun hale getirilebilir ve şebekeye bağlı PV sistemler bu tahminleri kullanarak elektrik pazarında teklif verirken kendi stratejilerini geliştirebilir ve sistem operatörleri rezervlerin daha iyi düzenlenmesini sağlayabilirler. Tek bir PV sisteminin çıkış gücü, yerel hava değişikliklerinden oldukça fazla etkilenmektedir.

Eğer enterkonnekte sistemde büyük güçlü PV elektrik üretim santralleri varsa bulutlanma durumunda şebekede ciddi bozulmalar meydana gelebilecektir. Bu durumda, PV çıkışındaki güç oldukça büyük ve ani bir değişim gösterecektir. Işınımdaki bu değişim, yükün hızlı bir şekilde artması sırasında meydana geldiğinde, durum daha da şiddetlenecektir [21]. Bu nedenlerden dolayı, güvenilir tahmin araçlarının bulunmasının, PV teknolojilerinin yaygınlaştırılması, PV sistemlerinin planlama ve işletim aşamalarındaki

performansını optimize etmek ve nihai olarak ekonomik getiriye doğru bir şekilde değerlendirmek için çok önemli olduğu açıktır. PV panellerinin gerçek performansını değerlendirmek için güç çıkışının doğru tahmin edilmesi çok önemlidir. Daha düşük bir güneş ışınımı ile birlikte PV panel sayısının artışı, sistemin dönüştürme verimliliğini önemli ölçüde düşürebilir ve böylece güç çıkışını düşürebilir [22]. Bir PV panelin verimini elde etmede önemli bir husus, herhangi bir hava koşulu için performansı değerlendirmek ve maksimum güç noktasını eşleştirmektir. Literatürde Maksimum Güç Noktası Yöntemine (MPPT) dayanan birçok yöntem önerilmiştir. Bu yöntemlerin çoğunda PV sisteminin termoelektrik performansını değerlendirmek için ampirik korelasyon uygulanmıştır. Bununla birlikte, bu yaklaşımlar PV sisteminin fiziksel parametreleri ve üretim özellikleri hakkında ayrıntılı bilgi gerektirir. Bir diğer yaklaşım ise uyarlamalı sistemler tabanlıdır. Uyarlamalı bir sistem, davranışını ortamdaki veya sistemin bir bölümündeki değişikliklere göre uyarlayabilen bir sistemdir. Uyarlanabilir bir sistem, bir PV paneli için herhangi bir fiziksel tanımlama gerektirmez; değişen hava koşullarında PV modülünün güç çıkışını hızlı ve güvenilir bir şekilde tahmin edilmesini sağlayabilir.

1.1.Literatür Çalışması

Güneş ışınımı, PV panelin çıkış gücünü belirleyen en önemli parametrelerden biridir. Bu nedenle, solar güç tahmini ya doğrudan ya da güneş ışınımı ile dolaylı olarak tahmin edilebilir. Literatürde güneş ışınımının tahmini için sayısal hava tahmin yöntemleri, görüntü tabanlı tahmin yöntemleri ve istatistiksel tahmin yöntemleri olmak üzere üç temel tahmin yöntemi önerilmiştir.

Güneş enerjisi tahmin yöntemleri, fiziksel, istatistiksel ve hibrit yöntemler olmak üzere üçe ayrılmaktadır.

Fiziksel yöntem, sıcaklık, basınç, nem ve bulut gibi fiziksel verileri kullanarak veya uydu gözlem verileri kullanılarak atmosfer bulut gözlemlerine göre sayısal hava tahmini yapılmasına dayanır.

Ref. [23]'te, Avrupa Orta Vadeli Hava Tahmin Merkezi bir gün sonraki küresel yatay ışınımın tahmin doğruluğu değerlendirilmiştir.

Ref. [24]'te, Güney İspanya için WRF mezosel atmosferik modeli tarafından sağlanan üç gün sonraki küresel yatay ışınım ve doğrudan normal ışınım tahminlerinin güvenilirliği değerlendirilmiştir. Bu çalışmada, küresel yatay ışınım tahminleri doğrudan modelden üretilirken, doğrudan normal ışınım tahminleri ise WRF çıktıları ve uydu verileri

kullanılarak fiziksel bir son işlem prosedürüne göre elde edilmiştir. Ref. [25]'de, Kanada'nın küresel çoklu ölçek modelinden küresel yatay ışıının 48 saat sonraki tahminlerinin doğruluğu değerlendirilmiştir. Bu model, günde dört defa çalıştırılmıştır. Tahmin sonuçları, Kuzey Amerika üzerinden on yer istasyonu vasıtasıyla doğrulanmıştır. En düşük hatanın günlerin çoğunun güneşli olduğu yerlerde ve en yüksek hatanın ise karmaşık bir hava dağılımına sahip yerlerde meydana geldiği görülmüştür. Ref. [26]'da, ABD Ulusal Dijital Tahmin veri tabanının tahmin doğruluğu incelenmiştir. Bu model, üç ya da altı saatlik bulut endeksi tahmini, yerel bir korelasyon fonksiyonu aracılığıyla saatlik küresel yatay aydınlanma tahminine dönüştürülmüştür. Ref. [27]'de, görüntü tabanlı kısa süreli bir güneş ışıının tahmin yöntemi önerilmiştir. Tahmin, 2.5 x 2.5 km uzamsal çözünürlük ve 30 dakikalık geçici çözünürlük ile uydu tarafından alınan görüntülerin istatistiksel analizi ile yapılmıştır. Ref. [28]'de uydu görüntüsü tabanlı bir güneş ışıının tahmin yöntemi önerilmiştir. Bu çalışmada piksele bağlı olarak bulut hareketi, iki ardışık uydu görüntüsünün analizinden tahmin edilmiştir.

Güneş ışıınının geçmiş verilerine dayanan tahmin yöntemleri istatistiksel ve akıllı sistemler tabanlı olmak üzere iki kategoriye ayrılır. Mevsim analizi, Box-Jenkins veya Otomatik Regresif Entegre Hareketli Ortalama (ARIMA), Çoklu Regresyonlar ve Üstel Düzleştirme gibi yöntemler istatistiksel yöntemlere ve bulanık çıkarım sistemleri, genetik algoritma, sinir ağları gibi yöntemler ise akıllı sistemler tabanlı tahmin yöntemlerine örnek verilebilir.

Ref. [29] 'da, ileri beslemeli sinir ağı, radyal tabanlı sinir ağı, tekrarlayan sinir ağı, dalgacık sinir ağı ve sinirsel bulanık ağ kullanılarak saatlik, günlük ve aylık güneş ışıının tahminleri yapılmıştır. Aylık güneş ışıının tahmini doğruluğu ortalama mutlak yüzde hataya göre değerlendirilmiştir ve bu hata % 0.3 ila % 16.4 arasında değişmektedir.

Ref. [30]'da, günlük güneş ışıının yapay sinir ağları kullanılarak tahmin edilmiştir. Bu modele giriş, günlük minimum ve maksimum hava sıcaklığı, yağış miktarı, açık gökyüzü ışıının değerleri kullanılmıştır.

Ref. [31] Suudi Arabistan'daki 41 istasyonundan elde edilen meteorolojik verileri kullanarak sinir ağları ile güneş ışıının tahmini yapmıştır. Bu çalışmada sinir ağına giriş olarak enlem, boylam, yükseklik ve güneş ışıının süresi alınmıştır. Güneş ışıının değerleri % 16.4'lük bir ortalama bağlı hata ile tahmin edilmiştir.

Ref. [32]'de, güneşlenme süresinin ölçümlerinden güneş ışıının tahmin etmek için bulanık mantık önermiştir. Bu yaklaşım, Türkiye'nin batısındaki aylık ortalama günlük ışıının üç

saha için uygulanmıştır. Bu çalışmada, güneş ışıyım tahminlerinin gerekli bulanık kural tabanı verilmiş ve Türkiye'nin batı kesimindeki bazı istasyonlara farklı enlemlerde uygulanmıştır. Ref. [33], güneş ışıyımını tahmin etmek için sinir ağıları kullanmışlardır. Ağa giriş verileri; konum, ay, ortalama basınç, ortalama sıcaklık, ortalama buhar basıncı, ortalama bağıl nem, ortalama rüzgar hızı ve ortalama güneş ışıyımının süresidir. Bu çalışmada, güneş ışıyımı % 93'lük bir doğruluk ve % 7.3'lük ortalama mutlak yüzdesi hatası ile tahmin edilmiştir.

Ref. [34]'te, sinir ağı ve Markov zinciri tabanlı hibrit bir model önerilmiştir. Ref. [35]'de derin öğrenme tabanlı güneş ışıyım tahmin yöntemi önerilmiştir. Ref. [36] 'da, Çin'de 250 kW'lık bir PV sistemi için günlük enerji üretimini tahmin etmek üzere bir fiziksel model geliştirilmiştir. Güneş ışıması ve PV hücreleri performansını modelleyerek günlük tahmin hatası % 5.24'ten % 13.14'e artmıştır. Ref. [37]'de, 1 MW'lık bir PV sistemi için fiziksel model ve ileri besleme sinir ağı modelinin tahmin doğruluğu karşılaştırılmıştır. Bu çalışmada oluşturulan fiziksel model, bir güneş ışıyım modeli ve bir PV hücre modelinden oluşmaktadır. İleri beslemeli sinir ağı modeline girişler sıcaklık, bulut, ışıyım ve güneşin konumu kullanılmıştır. Bir yıllık süre için, normalize ortalama karesel hata fiziksel model için % 12.45, ileri besleme sinir ağı modeli için % 10.5 bulunmuştur. Ref. [38]'de, PV güç çıkışı tahmini için iyileştirilmiş ileri beslemeli bir sinir ağı modeli önerilmiştir. Sinir ağı modeli parçacık sürüşü optimizasyon algoritması kullanılarak iyileştirilmiştir. Sinir ağı modelinde iki gizli katman vardır ve bu ağa girişler gün, zaman, bulutluluk indeksi, hava sıcaklığı, rüzgar hızı, hava nemi, ışıyım, yağış ve hava basıncıdır. Ref. [39]'da günlük enerji üretiminin tahmini için sinirsel bulanık ağı önerilmiştir. Gün, ışıyım, hava sıcaklığı, rüzgar hızı, hava nemi ve hava basıncı sinirsel bulanık ağı giriş olarak verilmiştir. Bu modelin tahmin doğruluğu üç PV tesisinden elde edilen veriler ile değerlendirilmiş ve ortalama tahmin hatası % 5 olarak bulunmuştur. Ref. [40]'da, destek vektör makinesini ve bir hava sınıflandırma yöntemini birleştiren hibrit bir model, Çin'de 20 kW'lık bir PV istasyonunun PV güç tahmini için önerilmiştir. Eğitim seti, hava durumuna göre dört gruba ayrılmış ve her bir eğitim seti dört destek vektör makinesi modelini eğitmek için kullanılmıştır. Tahmin edilen günün hava durumu türlerine göre, uygun destek vektör makinesi modeli seçilmiştir. 15 dakikalık aralıklarla alınan veriler bir günlük sonraya yönelik tahminler, % 10.5'lik bir ortalama karesel hatayla elde edilmiştir. Her bir destek vektör makinesi için ortalama karesel hata, bulutlu model için % 9.12, sisli model için % 12.6, yağmurlu model için % 12.4 ve güneşli model için % 7.85 olmuştur.

Ref. [41] ‘de, bir güç destek vektör makinesini ve benzer bir gün yöntemini birleştiren bir melez model güç çıkışı tahmin etmek için kullanılmıştır.

Ref. [42], makine öğrenmesi, görüntü işleme ve akustik sınıflandırma teknikleri tabanlı PV güç tahmini için yeni bir yöntem önerilmiştir.

Ref. [35], derin öğrenme tabanlı bir sinir ağı güneş ışıınımını tahmin etmek için önerilmiştir. Önerilen yöntemin sonuçları, destek vektör makineleri ve ileri besleme sinir ağıları yöntemlerinden elde edilen sonuçlarla karşılaştırılmıştır.

1.2. Tezin Amacı

Gelişen dünyada, dünya nüfusunun artması, günümüzde toplumun ihtiyaçlarının değişmesi, buna nazaran sanayi ve teknolojinin gelişmesiyle enerjiye duyulan gereksinim giderek artmaya devam etmektedir. Günümüzde daha çok kullanılan fosil yakıtlı enerji üretim sistemleri dünyadaki enerji tüketim talebini karşılamaktadır. Ancak mevcut rezervlerin bir gün tükeneceği düşünülerek araştırmacılar, var olan enerji kaynaklarının yanı sıra tükenmeyen ve çevreye daha az zarar veren alternatif enerji kaynaklarının bulunmasına ve bu kaynakların etkin bir şekilde kullanılmasına yönelik çalışmalara odaklanmışlardır. Yenilenebilir enerji kaynakları arasında en yaygın faydalanılan ise güneş enerjisidir.

PV tabanlı elektrik üretiminin artışı, geleneksel fosil yakıt temelli teknolojilere kıyasla çevre için avantajlar sağlamaktadır. Bununla birlikte, PV sistemlerin doğal değişkenliği, enerjisinin çoğunu güneşten sağlayan sistemler için bir dezavantajdır. Bu dezavantajı en aza indirmek için PV hücrelerin maksimum güç noktasında çalıştırılması gerekmektedir. Ancak, bir PV hücre geniş bir gerilim (V) ve akım (I) aralığında çalışabilmektedir. Bir PV hücrenin sağlayabileceği maksimum güç, sürekli olarak ışıınım alan bir PV hücredeki direnç yükünü sıfırdan (kısa devre) çok yüksek bir değere (açık devreye) kadar sürekli arttırarak belirlenebilir. Maksimum güç noktasında $V \times I$ en yüksek değerini alır. Bu noktada, PV hücre bulunduğu ışıınım seviyesinde maksimum gücü üretir. Güneş pillerinde her çalışma koşuluna denk gelen yalnızca bir tane maksimum güç noktası vardır. Güneş panellerinden maksimum verim elde edebilmek için panel, bu maksimum güç noktasında çalıştırılmalıdır. Güneş pilleri, maksimum gerilim noktası V_{MPP} ve maksimum akım noktasında I_{MPP} maksimum güç üretir. Çalışma koşullarında meydana gelen değişkenliğin üstesinden gelmek ve PV hücrenin üretebileceği maksimum gücü belirleyebilmek için literatürde farklı maksimum güç izleme noktası yöntemleri önerilmiştir. Uygulamada değiştir-gözle, artan-iletkenlik, bulanık mantık, bakma tablosu, sabit akım ve sabit gerilim, sadece akım ve

gerilim, parazitik kapasitans, dalgalanma korelasyon kontrolü gibi bazı yöntemler önerilmiştir. Bu yöntemlere ek olarak, akıllı sistemler kullanılarak PV çıkış gücü çalışma şartlarına bağlı olarak tahmin edilebilir. YSA, destek vektör makinaları ve sinirsel bulanık sistemler önceki çalışmalarda PV sistemlerin çıkış gücü tahmini için yaygın olarak kullanılmıştır. Bununla birlikte, YSA'ların öğrenme hızı gerekenden çok daha zaman alıcıdır. YSA'ların bu özelliği, uygulamalarında en önemli sınırlamadır. Ref. [43] bu davranışın iki ana nedenden kaynaklandığını belirtmiştir. Bunlardan biri sinir ağını eğitmek için kullanılan yavaş eğim düşüm tabanlı öğrenme algoritmalarıdır ve diğer nedenler ağların parametrelerinin bu öğrenme algoritmaları ile tekrarlı olarak ayarlanmasıdır. YSA'ların bu dezavantajlarını gidermek için, Ref. [43] tarafından Uç Öğrenme Makinesi (UÖM) olarak bilinen yeni bir öğrenme algoritması önerilmiştir.

Bu tez çalışmasında, farklı çalışma şartları altında bir PV panelin çıkış gücü uç öğrenme algoritması (UÖM) yardımı ile tahmin edilmeye çalışılmıştır. Bu amaçla 180 W gücünde bir PV panel kurulmuş ve bu panelin açık devre gerilimi, kısa devre akımı, panel sıcaklığı ve güneş ışınlamı belirli aralıklarla ölçülerek kaydedilmiştir. Toplam 75 adet ölçüm verisi elde edilmiştir. Açık devre gerilimi ve kısa devre akımından panelin maksimum gücü hesaplanmıştır. UÖM kullanılarak oluşturulan PV panelin regresyon modeline giriş olarak panel sıcaklığı ve güneş ışınlamı verilirken, regresyon modelinin çıkışı PV panelin maksimum gücü olarak alınmıştır. UÖM'nin bazı parametreleri (giriş nöron sayısı, aktivasyon fonksiyonu) deneme yanılma yöntemi ile en iyi sonucu verecek şekilde ayarlanmıştır. Oluşturulan veri kümesi eğitim ve test kümeleri olarak ayrılmıştır. Yöntemin başarımı 5-katlamalı çapraz doğrulama yöntemi ile incelenmiştir. Bu amaçla, veri kümesi 5 eşit parçaya bölünmüştür. Bu parçalardan biri test için ayrılıp geri kalan dördü ağın eğitimi için kullanılır ve bu işlem her defasında test kümesi değiştirilerek gerçekleştirilir. Toplamda 5 defa ağ farklı kümelerle eğitilip test edilmiş olur. Ağın test sonucunda, bütün test fonksiyonlarının performanslarının toplamının ortalaması alınır. UÖA algoritması MATLAB yazılımı kullanılarak gerçekleştirilmiştir. Ayrıca PV panelin çıkış gücünün tahmini için farklı regresyon modelleri de kullanılmış ve bu modellerden elde edilen sonuçlar UÖM'nin sonuçları ile karşılaştırılmıştır. Elde edilen regresyon sonuçlarından, UÖM'nin PV panelin çıkış gücünü çok yüksek doğrulukta tahmin ettiği görülmüştür. Ayrıca UÖM'nin eğitim süresinin diğer regresyon modellerine göre daha kısa ve eğitim algoritmasının çok basit olması gibi üstünlükleri UÖM'yi PV panellerin çıkış gücünün tahmininde etkin bir araç olarak kullanılabileceğini göstermiştir.

Bu tez çalışması aşağıdaki gibi organize edilmiştir:

Birinci bölümde genel olarak ülkemizde ve dünyada elektrik enerjisi ve yenilenebilir enerji kaynağı olan güneş enerjisi hakkında bilgi verilmiştir. Ayrıca literatürde yapılan çalışmalara değinilmiş ve tezin amacı belirtilmiştir. İkinci bölümde PV paneller tanıtılmıştır. Üçüncü bölümde MPPT hakkında bilgi verilmiştir. Dördüncü bölümde UÖM anlatılmıştır. Beşinci bölümde, UÖM'nin tahmin başarımını göstermek için UÖM'den elde edilen deneysel sonuçlar verilmiştir. Ek olarak farklı regresyon modelleri kullanılarak ta sonuçlar ayrıca irdelenmiştir. Altıncı bölümde ise elde edilen sonuçlar tartışılmıştır.



2. PV SİSTEMLER

Fotovoltaik Yunanca, ışık anlamına gelen *photo* ve elektrik akımını geliştiren makinayı tasarlayan *Alessandro Volta*'dan esinlenerek gerilim anlamına gelen *voltaic* kelimelerinin birleşmesinden oluşur. PV hücreler, güneş ışınlarını doğrudan elektriğe dönüştürebilen yarı iletken tabanlı sistemlerdir. Yarı iletken bir diyot olan PV hücre, güneş ışığının enerjisini fotoelektrik reaksiyondan faydalanarak doğrudan elektrik enerjisine dönüştürür. PV hücrenin yapısına bağlı olarak, hücreler güneş enerjisini % 5 ile % 20 arasında bir verimle elektriğe dönüştürülebilir. PV hücrelerin yüzeyleri genellikle kare, dikdörtgen ve daire biçimindedir. PV hücrelerin alanları da, 60–160 cm² arasında değişmekte olup, ortalama 100 cm²'dir. Kalınlıkları ise 0.2 – 0.4 mm arasındadır.

Günümüz pazarında farklı yarı iletken malzemeler farklı PV teknolojileri tarafından kullanılmaktadır. PV teknolojileri, birinci nesil, ikinci nesil ve üçüncü nesil olmak üzere üçe ayrılabilir. Bu sınıflandırma kullanılan malzemeye göre yapılmıştır [6].

➤ **Birinci Nesil Kristal Silikon PV Hücreler:** Bu PV hücreleri tek kristalli ve çok kristalli olmak üzere ikiye ayrılabilir. Günümüzde PV sistemlerin yaklaşık % 80'i bu malzemeden yapılmaktadır. Bu PV'lerin verimi % 16 ile % 19 arasında değişmektedir. Dünyamız, PV uygulamaları için uygun yarı iletken bir malzeme olan silikon açısından zengindir. Bu malzeme kullanılarak PV'ler, silikon üretimi, silikon devre üretimi, hücre üretimi ve model montajı olmak üzere dört aşamadan oluşmaktadır [44].

➤ **İkinci Nesil İnce Film PV Hücreler:** İkinci nesil PV hücreler, ince film teknolojisine dayanmaktadır. Bu teknoloji, düşük maliyetli üretime sahiptir ve verimliliği % 12 ile % 20 arasında değişmektedir. Küresel PV modül pazarının yaklaşık % 15'ini ince film PV'ler oluşturmaktadır. İnce film PV teknolojisinin üç temel türü vardır. Bu nesil hücreler amorf silikon, kadmiyum tellür ve bakır indiyum selenitten yapılırlar [44]. Amorf silikon PV modülünün verimliliği % 10 ile % 12 arasında değişmektedir. Amorf silikon güneş pilleri kristal-silikon tabanlı bir güneş pilinden daha ucuzdur. Bir kristal-silikon tabanlı güneş pili üretmek için sadece % 1'lik silikon kullanılır. Amorf silikon hücrenin başlıca dezavantajı güneşin yol açtığı zaman içinde performans bozulmasıdır. Bu problem % 35'e varan güç çıkışında bir azalmaya neden olur. Diğer taraftan, daha ince tabakalar, malzeme boyunca elektrik alan kuvvetini arttırarak daha iyi kararlılık ve daha az güç çıkışı düşümü sağlayabilir. Ayrıca amorf silikon güneş panelleri aynı PV sistem kapasitesi için kristal


temelli güneş panellerine kıyasla daha geniş bir alanı kaplamaya ihtiyaç duyar [45-46]. Kadmiyum tellür PV modüllerinin ince film modülleri arasında en düşük maliyete sahip olduğu düşünülmektedir ve bu malzemeden yapılan PV hücrelerin verimliliği % 15 civarındadır. Bu modüller en çevre dostu güneş modülleri olarak kabul edilir. Bu tür panellerin üretiminde daha az enerji tüketilir. Kadmiyum tellür ince filmli PV hücrelerinin tahmini üretim maliyeti 0,75 \$ / W'ın altındadır. Kadmiyumun zehirli bir metal olması bu hammaddenin kullanımını sınırlandırmaktadır. Bu nedenle, üretim sırasında kadmiyum kullanımı işçilerin sağlığını korumak için izlenmeli ve kontrol edilmelidir. Diğer hammadde tellür, daha düşük miktarlarda üretilmektedir.

➤ **Üçüncü Nesil PV hücreler:** Birinci nesil güneş pillerinin yüksek maliyeti ve ikinci nesil güneş pilleri için sınırlı malzeme bulunması nedeniyle, yeni nesil güneş pilleri ortaya çıktı. Halen, sektörde Üçüncü nesil güneş pilleri olarak adlandırılan şeylerle ilgili birçok güneş araştırması var. Üçüncü jenerasyon güneş pilleri doğal olarak önceki iki jenerasyondan farklıdır. Bu yeni nesil PV'ler, nano malzemeler, silikon teller, geleneksel baskı makineleri kullanan güneş mürekkepleri, organik boyalar ve iletken plastikler dahil olmak üzere silisyumun yanı sıra çeşitli yeni malzemelerden üretilmektedir. Esas amaç ticari olarak temin edilebilen PV geliştirmek ve güneş enerjisinden elektrik üreten PV'lerin verimini artırmak, daha ucuz ve zehirli olmayan daha fazla insan tarafından kullanılmasını sağlamaktır.

Bu hücreler kendi arasında III-V grubu PV hücreler, kuantum hücreler ve çok eklemli hücreler olarak ayrılabilirler. Ayrıca, konsantre PV'ler, organik PV'ler ve Ar-Ge aşamasında olan diğer PV hücreler üçüncü nesil PV hücrelere örnek gösterilebilirler.


Tipik bir PV hücresinin basit yapısı Şekil 2.1'de görülmektedir. PV hücrenin üst yüzeyi yansıma önleyici tabaka ile kaplanmıştır. Bu kaplamanın kullanım amacı, yansıma katsayılarını düşürerek, mümkün olduğu kadar fazla sayıda fotonun soğurulmasını sağlamaktır. Ayrıca foton akımlarını toplamak için hücre yapısında bulunan p tipi ve n tipi yarı iletkenlerin her iki tarafına metal kontaklar yerleştirilmiştir. P tipi ve n tipi yarı iletkenlerin birleşim bölgesi ise p-n eklemine oluşturur [45].

PV hücrelerin çalışma ilkesi fotovoltaiik olayına dayanır. Üzerine ışık düştüğü zaman uçlarında bir potansiyel fark oluşur. Fotovoltaiikte, güneş ışığını soğuracak malzeme, yasak enerji aralığı güneş spektrumu ile uyumlu ve elektrik yüklerinin birbirinden ayrılabilmesine izin verebilecek özellikte bir yarı iletken olmalıdır. Temel olarak, bir PV hücre n-tipi ve p-tipi yarı iletken malzemeden yapılır. Bu n-tipi ve p-tipi bölgelerin geçiş bölgesindeki p-n eklemi kesiminde, doğal olarak bir elektrik alanı meydana gelir [45].



Şekil 2.1. Güneş pilinin iç yapısı


PV hücrenin yapısında bulunan yarı iletken malzemeler ince levhalar şeklinde bulunurlar ve bir tarafta pozitif ve diğer tarafta negatif olan bir elektrik alanı oluşturmak için özel olarak tasarlanmışlardır. Pozitif tarafta 3 elektron, negatif tarafta ise 5 elektron bulunduran atomlar vardır. 5 elektron bulunduran atom elektron vermeye 3 elektron bulunduran atom ise elektron almaya elverişlidir. Işık enerjisi güneş hücresine çarptığında, elektron vermeye elverişli yarı iletken malzemedeki atomlardan elektronlar kopar. Pozitif ve negatif taraflara iletken bağlanırsa, bir elektrik devresi oluşturulur ve elektronlar elektrik akımı biçiminde yakalanabilirler. Bu elektrik enerjisi bir yüke güç vermek için kullanılabilir. Bir PV hücrenin temel elektriksel modeli Şekil 2.2'de gösterilmiştir [46, 47].



Şekil 2.2. Güneş pili temel elektriksel modeli

Bir PV sisteminin performansını tasarlamak ve değerlendirmek için doğru bir PV modeli, gerçek çalışma koşulları altında güvenilir bir akım-gerilim (I-V) ve güç-gerilim (P-V) eğrilerini tahmin etmeyi başarmalıdır. Bir PV sisteminin elektriksel davranışını iyi tanımlayan en yaygın eşdeğer devre, beş parametrelidir. Şekil 2.3'te gösterildiği gibi bu eşdeğer devre modeli, foto-akımı kaynağı I_L , şönt direnç R_{sh} , bu dirence

paralel bir diyot ve seri direnç R_s 'den oluşmaktadır. Hücre üzerine düşen ışınlam miktarı arttıkça üretilen elektrik akımı da artmaktadır. Güneş pili gövdesi yarı iletken malzeme olması nedeniyle bir diyotla gösterilmiştir. Güneş pilinden elde edilen gerilim ise V olarak gösterilmektedir. Çıkış ucuna seri bağlı olarak gösterilen direnç değeri R_s hücreyi oluşturan yarı iletken malzemenin direnci ile hücrelerin birbirine bağlantı noktalarında oluşan temas dirençlerinin toplamına eşittir. Paralel (şönt) direnç R_{sh} ise çok ince katmanlardan oluşan ince film yapısına sahip malzemeler de katmanlar arasında ve hücre çevresinde oluşan dirençlerin toplamı olarak alınmaktadır. Yapılan incelemelerde seri direnç değerinin paralel dirence oranla çok küçük olduğu ve ihmal edilebileceği belirlenmiştir. Devrenin asıl direnci seri direnç olarak kabul edilebilir. İdeal durumda R_s sıfır ve R_{sh} sonsuzdur. Ancak, bu ideal durum mümkün değildir ve üreticiler ürünlerini geliştirmek için her iki direncin etkisini en aza indirmeye çalışırlar [48].



Şekil 2.3. Omik bir yükü besleyen bir güneş pili için basitleştirilmiş tek diyot eşdeğer devresi

Kirchhoff kanunundan hücrenin çıkış akımı I_L :

$$I = I_L - I_D - I_{sh} \quad (2.1)$$

şeklinde elde edilebilir. Diyot akımı I_D ise aşağıdaki gibi yazılabilir.

$$I_D = I_0 \left[\exp \left(\frac{q(V + R_s I)}{n \cdot k \cdot T} \right) - 1 \right] \quad (2.2)$$


Bu denklemde, k ; Boltzman sabitini, q ; birim elektron yük miktarını, T ; Kelvin cinsinden hücrenin mutlak sıcaklığını göstermektedir. Denk.2.1 denk.2.2’de yerine yazılırsa:

$$I = I_L - I_0 \left[\exp \left(\frac{q(V + R_s I)}{n \cdot k \cdot T} \right) - 1 \right] - \frac{V + I \cdot R_s}{R_{sh}} \quad (2.3)$$

Denklemleri elde edilir [48].

Bilindiği gibi, bir fotovoltaik panelin performansı, 25 ° C’lik bir hücre sıcaklığında 1 kW / m²’lik bir güneş ışınlamı (I_r) aldığı anda panel tarafından sağlanan maksimum elektrik enerjisini tanımlayan maksimum güce göre tanımlanır. Verilen I_r , T_c ve R_L değerleri için,

çalışma noktası I-V karakteristiğinde farklı yük hatlarının çizilmesi ile tanımlanabilir (Şekil 2.4). Maksimum güç noktaları kırmızı dairelerle gösterilmiştir.




Şekil 2.4. Sabit sıcaklıkta (25°C), değişken ışınímda ($1000 - 200 \frac{\text{W}}{\text{m}^2}$) bir PV panelin çalışma noktası ve elektriksel yükü; a) $1000 \frac{\text{W}}{\text{m}^2}$ sabit ışınímda, $25^{\circ}\text{C} - 75^{\circ}\text{C}$ değişen sıcaklıkta, b) $1000 - 200 \frac{\text{W}}{\text{m}^2}$ değişken ışınímda, 25°C sabit sıcaklıkta

Gerçek şartlarda, çalışma koşulu, güneş ışıını, rüzgar hızı, hava sıcaklığı ve elektrik yükü gibi olası koşullar altında değerlendirmek gerekir. Hücre sıcaklığı bir PV panelinin enerji dönüştürme verimliliğini değiştiren önemli bir parametredir: Hücre sıcaklığının artması, üretilen enerjinin azalmasına neden olur.

PV hücreler, bir PV modülü oluşturmak için seri olarak ve PV modülleri, bir PV dizisi oluşturmak için ise seri ve paralel olarak birbirine bağlanırlar. Şekil 2.5 (a), bir PV dizisinin şeması gösterilmiştir ve siyah bir dikdörtgen çerçeve ile gösterilen bileşen PV hücresidir. Yüzey alanı sınırlaması nedeniyle, tek bir hücre tarafından üretilen güç sınırlıdır. Örneğin, 100 cm^2 tek kristalli bir silikon PV, maksimum güneş ışığına maruz kaldığında en fazla 1.5 W güç üretebilir [49]. Gerçek bir uygulama için bir hücreden elde edilen güç yeterli değildir. Bu nedenle, PV hücreler daha yüksek bir çıkış gerilimi elde etmek için seri ve daha yüksek bir çıkış akımı elde etmek için paralel olarak bağlanırlar. Daha yüksek güce ihtiyaç duyulursa, bir PV dizisi yapmak için birkaç PV modülü birbirine bağlanır. Şekil 2.5 (b)'de tipik bir kristal silikon PV hücresinin şeması gösterilmiştir [50]. PV hücresi, bir ön temas,

yansımaya önleyici bir tabaka, bir P-tipi yarı iletken malzeme, bir N-tipi yarı iletken malzeme ve bir arka kontakten oluşur.


İyi bir iletken den yapılan ön kontak, elektronları toplamak için kullanılır. Arka temas metalden yapılmıştır ve bir iletken olarak kullanılır. Ayrıca arka yüzeyi korur. Yansımaya önleyici bir tabaka, farklı kırılma indisi ve kalınlığa sahip camların birleşiminden oluşur. Bu tabaka, PV hücrelerinin daha fazla güneş ışığı almasına ve yansımaya azaltılmasına yardımcı olur. N-tipi silisyum yarı iletken tabaka, normal silisyumdan daha fazla bir değerlik elektronu içeren katkılı bir katmandır; P-tipi silisyum yarı iletken tabaka, normal silisyumdan daha az değerlikli elektron içeren katkılı bir katmandır. Silisyum atomlarını bağlamak için sadece dört elektrona ihtiyaç vardır, bu nedenle N-tipi silisyum valans elektronlarını bağlama eğilimindedir ve p-tipi silisyum değerlik elektronlarını benimseme eğilimindedir. N-tipi ve P-tipi silisyumun bağlantısı bir elektrik alanı içeren ve N-tipi silisyumdan P-tipi silisyuma elektronların hareketine direnç gösteren bir P-N bağlantısını oluşturur. Kalın P-tipi silisyum tabaka, güneş ışığının çoğunu emer ve gücün çoğunu üretir [51]. Yeterli enerjiye sahip güneş ışığı silisyuma çarptığında, elektronlar temas noktasından yüke doğru ve tekrar temas noktasına geri dönmeye zorlanacaklardır [49].



Şekil 2.5. (a) PV hücreleri, PV modülleri ve PV dizileri (b) Kristalli bir silikon güneş pilinin yapısı [50]

Güç çıkışını artırmak amacıyla çok sayıda PV hücre birbirine paralel ya da seri bağlanarak bir yüzey üzerine monte edilir. Bu yapıya PV modül adı verilir. Güç talebine bağlı olarak PV modüller birbirlerine seri veya paralel olarak bağlanarak birkaç W'den

MW'ye kadar PV paneller ve diziler oluşturulur [52]. Şekil 2.6'da PV hücre, modül, panel ve dizi gösterilmiştir.



Şekil 2.6. PV hücre, modül, panel ve dizi


Literatürde maksimum güç noktasını bulmak için farklı algoritmalar önerilmiştir [53-55]. Dolaylı yöntemlerde maksimum güç noktası ışıyım veya ampirik veriler kullanarak sayısal yaklaşımların matematiksel ifadeleri PV modüllerin gerilim ve akım ölçümlerinden tahmin edilmektedir. Literatürde tanımlanan maksimum güç noktası izleme (MPPT) yöntemlerinin çoğunda, genel bir PV sisteminin optimal çalışma noktası doğrusal yaklaşımlarla tahmin edilmektedir [56]. Bu durum denklem 2.4'te gösterilmiştir.

$$V_{mpp} = k_v \cdot V_{oc} \quad \text{veya} \quad I_{mpp} = k_i \cdot I_{sc} \quad (2.4)$$

Denklem 2.4'te; V_{mpp} ; Maksimum gerilim, I_{mpp} ; maksimum akım, V_{oc} ; açık devre gerilimi; I_{sc} ; kısa devre akımı; k_v ve k_i ise sırası ile kullanılan PV modüle bağlı gerilim ve akım sabitleridir.


Bununla birlikte, maksimum güç noktasını bulmak için doğrudan yöntemler de kullanılabilir; PV modül gerilim ve akım ölçümlerinden gerçek maksimum gücü elde etmenin avantajına sahiptirler. Bu durumda, gerilim ve akım herhangi bir ışık ışıyım ve sıcaklık için uygundur [57]. Son zamanlarda, bulanık mantık denetleyicileri ve yapay sinir ağı yöntemleri solar sistemlerde maksimum güç noktasının bulunması uygulamalarında yaygın olarak kullanılmaktadırlar [58-59].

Kısa devre akımı (ISC) ve açık devre gerilimi (VOC) ile I_r arasındaki ilişki Şekil 2.7'de [49] gösterilmiştir. ISC, güneş ışıyımı ile orantılıdır ve aynı zamanda hücre sıcaklığına da bağlıdır. Düşük sıcaklık katsayısı, sıcak havalarda güneş pilinin performansını artırabilir. VOC, doyma değerine ulaşıncaya kadar radyasyonla çok hızlı bir şekilde artar. Bu noktadan sonra, VOC çok yavaş büyüyecek ve bu yavaş büyüme genellikle iç ve dış dirençlerden dolayı gözlenemeyecektir.



Şekil 2.7. Işınım ile kısa devre akımı ve açık devre geriliminin ilişkisi

Bir PV hücrenin I-V ve P-V eğrileri Şekil 2.7'de verilmiştir. Bu eğriler boyunca herhangi bir noktada güneş pilinin akım, gerilim ve güç değerleri arasındaki ilişki şekilde gösterilmektedir. Bir güneş pilinin elektriksel performansı her zaman iki faktör ile tanımlanır. Bunlar ISC ve VOC'dir. ISC, eğrinin dikey eksenle kesiştiği noktadır ve devredeki maksimum olası akımdır. Bu akım değeri, hücrenin pozitif ve negatif uçları birbirine bağlanarak ölçülür. Uçlar kısa devre edildiğinde, devrenin çıkış gerilimi sıfırdır. Açık devre gerilimi VOC ise, eğrinin yatay eksenle kesiştiği noktadır ve devredeki olası maksimum çıkış gerilimini temsil eder. Bu gerilim değeri, PV hücreler çok büyük bir dirençe bağlandığında veya yük olmaması durumunda ortaya çıkar. Açık devre koşulu altında akım sıfırdır. Devreden kısa devre akımı ISC aktığı zaman çıkış gerilimi sıfır, açık devre durumunda ise çıkış akımı sıfır olduğundan, bu noktalarda çıkış gücü sıfırdır. Ayrıca PV hücrenin düşük çalışma gerilimi değerlerinde sabit bir akım kaynağı ve düşük işletme akımı değerlerinde sabit bir gerilim kaynağı olarak düşünülebilir. Bununla birlikte, şekil 2.8'de verilen egride maksimum güç noktası görülmektedir. Bu nokta bir PV hücresinden maksimum gücün alındığı noktadır [60, 61].




Şekil 2.8. Belirli bir sıcaklıkta ve güneş ışınımında bir güneş pilinin I-V ve P-V eğrisi

2.1. PV Hücresinin I-V Eğrisinden Maksimum Güç Noktasının Tespiti

Bir PV hücre, geniş bir gerilim (V) ve akım (I) aralığında çalışabilir. *Maksimum güç noktası*, sürekli bir ışınım altındaki bir PV hücresinin yükünü sıfırdan (kısa devre) çok yüksek bir değere (açık devreye) kadar sürekli arttırarak belirlenebilir. Maksimum güç noktasında $V \times I$ en yüksek değerini alır. Bu noktada, PV hücre bulunduğu ışınım seviyesinde maksimum gücü üretir. Çıkış gücü, hem kısa devre hem de açık devre sınır değerlerinin her ikisinde de sıfırdır. PV hücresinin üretebileceği en yüksek çıkış gücü, Şekil 2.9.'da görüldüğü gibi, hücresinin I-V eğrisi içine çizilebilecek maksimum alanlı dikdörtgenin alanına eşittir [62].

Güneş pillerinde her çalışma koşuluna denk gelen yalnızca bir tane maksimum güç noktası vardır. Güneş panellerinden maksimum verim elde edebilmek için panel, bu maksimum güç noktasında çalıştırılmalıdır. Güneş pilleri, maksimum gerilim noktası (V_{mpp}) ve maksimum akım noktasında (I_{mpp}) maksimum güç (P_{mpp}) üretir. Akım - gerilim grafiğinde maksimum güç ifadesi şu şekilde hesaplanır:


$$P_{mpp} = V_{mpp} \times I_{mpp} \quad (2.5)$$



Şekil 2.9. İdeal bir PV hücrenin I-V ve P-V karakteristikleri

2.2. Güneş Pillerinde Dolgu Faktörü ve Verim

Dolgu faktörü, bir PV hücrenin maksimum çıkış gücünü, açık devre gerilimi ve kısa devre akımına bağlı olarak tanımlamak için kullanılan bir değişkendir. Dolgu faktörü (FF), maksimum güç değerinin (P_{MPP}) açık devre gerilimi (V_{OC}) ve kısa devre akımı (I_{SC}) çarpımına bölünmesiyle belirlenir. Şekil 2.10' da bir PV hücrenin dolgu faktörünü gösteren karakteristik I-V eğrisi verilmiştir.



Şekil 2.10. Bir PV hücrenin dolgu faktörünü gösteren karakteristik I-V eğrisi [52]

Burada dolgu faktörü;

$$FF = \frac{I_{MPP} \cdot V_{MPP}}{I_{sc} \cdot V_{oc}} = \frac{\text{Yeşil Alan}}{\text{Mavi Alan}} \quad (2.6)$$

şeklinde hesaplanır.

Basit çarpımdan sonra aşağıdaki eşitlik elde edilir.

$$I_{sc} \cdot V_{oc} \cdot FF = I_{MPP} \cdot V_{MPP} = P_{MPP} \quad (2.7)$$

Dolgu faktörünün değeri, PV hücrenin ideallığının bir ölçüsüdür. İdeal bir PV hücrede, FF 1'e eşittir. Bu nedenle, herhangi bir PV hücrede dolgu faktörünün 1'e yakın olması istenir. Dolgu faktörü, hücrelerin seri ve şönt direnç değerlerinden ve diyot kayıplarından doğrudan etkilenir. Şönt direnç (R_{sh}) artırılarak ve seri direnç (R_s) azaltılarak FF yükseltilebilir. Bu durumda, hücre çıkış gücü teorik olarak en yüksek değere getirilerek daha yüksek verim sağlanır. Dolgu faktörü, normal silikon bir PV hücresi için yaklaşık olarak % 80 değerindedir. Dolgu faktörü, farklı PV hücrelerin performanslarını karşılaştırmada önemli bir rol oynar. Yüksek bir dolgu faktörü, düşük iç kayıplara sahip olan yüksek kaliteli bir PV hücre anlamına gelmektedir.

Bir güneş pilinin verimliliği ise hücresinden alınabilecek maksimum gücün, fotovoltaik hücrenin üzerine düşen güneş ışınım gücüne oranı olarak tanımlanır. Buna göre güneş pillerinin verimi (η);

$$\eta = \frac{P_{MPP}}{P_{in}} = \frac{I_{MPP} \cdot V_{MPP}}{P_{in}} \quad (2.8)$$

veya


$$\eta = \frac{V_{oc} \cdot I_{sc} \cdot FF}{P_{in}} \times 100(\%) \quad (2.9)$$

bağıntıları ile hesaplanabilir.

Burada P_{in} güneş pili hücreğine gelen toplam gücü (optik giriş gücünü), P_{MPP} ise güneş pilinin maksimum güç çıkışını ifade etmektedir. Güneş pillerinin verimliliklerinin ölçüldüğü, “Standart Test Koşulları” güneş pili 25°C de iken, 1000 W/m² güneş ışınımı altında yapılan ölçümdür. Bulutsuz ve güneşli bir günde 1200 W/m² ye varabilen bu değer, bulutlu günlerde 200-800 W/m² arasında değişmektedir [63].

2.3. Sıcaklığın PV Hücreye Etkisi

Bir PV hücrenin ve dolayısıyla da bu hücrelerin seri veya paralel bağlanmasıyla elde edilen bir PV modülün sıcaklığı, modülün çıkış gücü üzerindeki etkisinden dolayı önemli parametrelerden biri olarak kabul edilir [64].




Şekil 2.11. Bir PV modül için sabit ışınlam şartlarında sıcaklığın I-V ve P-V karakteristikleri üzerine etkileri

Şekil 2.11'de gösterildiği gibi açık devre gerilimi V_{oc} , modül sıcaklığındaki artıştan büyük ölçüde etkilenir. Sıcaklık sabit bir ışınlam seviyesi ile arttıkça, kısa devre akımı I_{sc} ’de çok küçük bir artış meydana gelir. Bunun sebebi PV hücrenin bant boşluğunun enerjisinin azalması ve daha fazla foton elektron deliği çifti oluşturmak için yeterli enerjiye sahip olmasındandır. Öte yandan, sıcaklık artışı ile, açık devre gerilimi V_{oc} ve dolum faktöründeki belirgin azalma nedeniyle PV modül çıkış gücünde bariz bir düşüş meydana gelmiştir; bu nedenle modül verimliliği azalır [61].

2.4. Işınnımın PV Hücresine Etkisi

Işınnım seviyesi arttıkça PV çıkış gerilimi ve akımın onunla birlikte arttığı açıktır [60]. Genel olarak, ışınnım seviyesindeki artış hücre sıcaklığında herhangi bir deęişiklik olmadığında maksimum güç voltajında teorik bir artışa yol açar. Diğer taraftan, kısa devre akımı I_{sc} , tamamen ve doğrusal olarak ışınnım seviyesine baęlıdır; bu nedenle bir PV modülün maksimum güç noktası Şekil 2.12 'de gösterildiğı gibi deęişmektedir. Burada Güneş ışınnımı şiddeti $Watt/m^2$ olarak ifade edilmektedir [64].

Güneş ışınnımı, birim alanda yer alan bir yüzeydeki güneş ışığının güç yoğunluğu olarak, metre kare başına *Watt* cinsinden ölçülen güneş ışıması şeklinde tanımlanabilir. Işınnım yoğunluğundaki artışla, hücre performansı doğrusal olarak artar. Işınnım şiddeti arttıkça, kısa devre akımı, fotoakım ve maksimum güç doğrusal olarak artar, ancak gerilim ve dolgu faktöründe çok az bir artış olur [65].



Şekil 2.12. Bir PV modül için sabit sıcaklıkta ışınnımın I-V ve P-V karakteristikleri üzerine etkileri


2.5. Şebeke Baęlantısına Göre PV Sistemler

PV sistemler güneş enerjisini doğrudan elektriğe dönüştürürler. PV sistemlere artan talebe baęlı olarak yakın gelecekte bu teknolojiye yapılan ar-ge bütçelerinin çok fazla artacağı ve PV teknolojilerinin verimlerinin de iyileştirileceğı öngörülmektedir. Bir PV sistem, temelde bir araya getirilen PV hücrelerinden oluşur. Daha fazla PV modülü, bir PV dizisi oluşturmak üzere gruplandırılır. Genel olarak bir PV modülü, bir inverter ve depolama sistemi gibi farklı yardımcı bileşenlerden meydana gelir.


Bir PV sisteminin şebekeye baęlı olup olmadığına baęlı olarak, şebekeye baęlı ve şebekeden bağımsız sistemler olarak ikiye ayrılabilirler.

2.5.1. Şebekeden Bağımsız PV Sistemler

Şebekeden bağımsız PV sistemler, güneş ışınlmı olmadığında (örneğin geceleri) veya çok sınırlı güneş ışınlmı olduđu zaman (örneğin bulutlu veya yağmurlu günlerde) invertere DC gerilim sağlamak için bir enerji depolama sistemine sahip olmalıdır [66]. Şebekeden bağımsız PV sistemler, uzak alanlarda bir ev veya bina için elektriksel güç sağlamak için kullanılabilir. Şekil 2.13 bir PV paneli, bir şarj regülatörü, bir batarya ve bir inverter içeren şebekeden bağımsız bir PV sisteminin tipik yapısını göstermektedir. Şarj kontrolörü aküyü çok fazla boşalmaya ve dolmaya karşı koruyabilir ve akünün verimli çalışmasını sağlayabilir. Akü, şarj regülatörü ile birlikte enerji depolama sistemidir ve bu sistem, yetersiz güneş ışınlmı olduğunda, PV sistemi için kritik öneme sahiptir. PV panellerden elde edilen DC gerilimi AC gerilime dönüştürmek için bir inverter kullanılır. Güneş ışınlmının düzensizliğinden dolayı, sadece bir PV güç kaynağı sistemi ya büyük bir güneş jeneratörüne ya da büyük bir pile ihtiyaç duyar. Bu nedenle, rüzgar ve dizel jeneratörler gibi farklı tipte jeneratörler tarafından çalıştırılan hibrit sistemler genellikle kullanılır [49]. Şekil 2.14'te rüzgar ve bir yedek jeneratörden oluşan hibrit bir PV sistemi gösterilmiştir. Uygun hava koşullarında, tüm güç PV ve rüzgar jeneratörü tarafından sağlanır ve pilin şarj edilmesi için fazla güç kullanılır. Olumsuz hava koşullarında veya geceleri, güç doğrudan dizel jeneratör tarafından sağlanır. Bataryanın boşalması durumunda, aküler dizel jeneratör tarafından şarj edilir.



Şekil 2.13. Şebekeden bağımsız PV sistemi




Şekil 2.14. Hibrit bir PV sisteminin blok şeması [49]

2.5.2. Şebekeye Bağlı PV Sistemleri

Şebekeye bağlı PV sistemler, inverterler aracılığıyla elektrik şebekesi ile sürekli bağlantılıdır. Şebekeye bağlı PV sistemler, dağıtık şebekeye bağlı PV sistemler ve merkezi şebekeye bağlı PV güç santralleri olarak ikiye ayrılabilirler.

Dağıtılmış şebekeye bağlı PV sistemler genellikle bir evin veya binanın çatısına monte edilir. Şekil 2.15 (a), dağıtılmış şebekeye bağlı bir PV sisteminin yapısı gösterilmiştir. Şebekeden bağımsız PV sistemi ile kıyaslandıklarında, bu sistemlerde enerji depolama birimleri yoktur. PV çıkış gücü yeterli olmadığında, yüklerin gücü elektrik şebekesinden çekilir. PV sistemin gücü fazla olduğunda ise üretilen güç şebekeye geri beslenecektir.



Şekil 2.15. Şebekeye bağlı PV sistemlerinin blok şeması [49]: (a) Dağıtılmış şebekeye bağlı PV sistemleri, (b) Merkezi şebekeye bağlı PV sistemleri

Şebekeye bağlı PV güç santralleri genellikle 1 MW'tan daha büyük kapasiteye sahiptir. Bu sistemler genellikle kullanılmayan araziler üzerine inşa edilir ve orta ve yüksek gerilim şebekesine bağlanır. Şekil 2.15 (b), merkezi şebekeye bağlı PV sistemlerinin yapısı gösterilmiştir. Dağıtılmış şebekeye bağlı sistemden farklı olarak, bu tür sistemler şebekeden güç çekmezler. PV sisteminin boyutuna ve yapılandırmasına bağlı olarak, inverterler farklıdır. Günümüzde, mikro inverterler güneş enerjisi verilerini web siteleri üzerinden yükleyebilir [67]. Dizi inverterler küçük PV sistemlerinde kullanılır ve bu inverterlerde bir MPPT bulunduğundan, bazı PV'ler MPP noktasında çalışmayabilir. Merkezi inverterler, 10 kW'tan büyük PV sistemleri için kullanılır ve merkezi inverterlerin maliyeti genellikle düşüktür.

2.6. Türkiye'nin Güneş Enerjisi Potansiyeli

Türkiye'nin coğrafi olarak 36-42° kuzey enlemleri ve 26- 45° doğu boylamları arasında bulunur. Güneşlenme süresi açısından Türkiye'nin coğrafi konumu ele alınırsa, birçok ülkeye göre çok avantajlı konumdadır.

Enerji ve Tabii Kaynaklar Bakanlığı tarafından hazırlanan, Türkiye'nin Güneş Enerjisi Potansiyeli Atlasına (GEPA) göre, Türkiye'nin ortalama yıllık toplam güneşlenme süresinin 2737 saat (günlük toplam 7,5 saat) ve ortalama toplam ışıınım şiddeti ise 1.527 kWh/m²-yıl (günlük toplam 4.2 kWh/m²) olduğu tespit edilmiştir [68]. Türkiye, 110 gün gibi yüksek bir güneş enerjisi potansiyeline sahiptir ve gerekli yatırımların yapılması halinde Türkiye yılda birim metre karesinden ortalama olarak 1.100 kWh'lik elektrik enerjisi üretilebilir [68]. Tablo 2.1'de Türkiye güneş enerji potansiyeli ve güneşlenme süresi değerleri aylara göre dağılımı verilmiştir.


Tablo 2.1. Türkiye 'nin toplam güneş enerjisi potansiyelinin aylara göre dağılımı

Aylar	Aylık Toplam Güneş Enerjisi		Güneşlenme Süresi
	(kcal/cm ² -ay)	(kWh/m ² -ay)	(saat/ay)
Ocak	4,45	51,75	103,0
Şubat	5,44	63,27	115,0
Mart	8,31	96,65	165,0
Nisan	10,51	122,23	197,0
Mayıs	13,23	153,86	273,0
Haziran	14,51	168,75	325,0
Temmuz	15,08	175,38	365,0
Ağustos	13,62	158,40	343,0
Eylül	10,60	123,28	280,0
Ekim	7,73	89,90	214,0
Kasım	5,23	60,82	157,0
Aralık	4,03	46,87	103,0
Toplam	112,74	1311,00	2640
Ortalama	308,0 cal/cm²-gün	3,6 kWh/m²-gün	7,2 saat/gün

Türkiye'nin en fazla güneş enerjisi alan bölgesi Güneydoğu Anadolu Bölgesi olup, bunu Akdeniz Bölgesi izlemektedir. Tablo 2.2'de Türkiye güneş enerjisi potansiyeli ve güneşlenme süresi değerlerinin bölgelere göre dağılımı verilmiştir.

Tablo 2.2. Türkiye'nin yıllık toplam güneş enerjisi potansiyelinin bölgelere göre dağılımı

Bölge	Toplam ortalama güneş enerjisi	En çok güneş enerjisi (Haziran)	En Az güneş enerjisi (Aralık)	Ortalama güneşlenme süresi	En çok güneşlenme süresi (Haziran)	En az güneşlenme süresi (Aralık)
	kWh/m ² - yıl	kWh/m ²	kWh/m ²	saat/yıl	saat	saat
Güneydoğu Anadolu	1.460	1.980	729	2.993	407	126
Akdeniz	1.390	1.869	476	2.956	360	101
Doğu Anadolu	1.365	1.863	431	2.664	371	96
İç Anadolu	1.314	1.855	412	2.628	381	98
Ege	1.304	1.723	420	2.738	373	165
Marmara	1.168	1.529	345	2.409	351	87
Karadeniz	1.120	1.315	409	1.971	273	82



Şekil 2.16. Türkiye'nin güneş radyasyon haritası ve aylara göre güneşlenme süreleri

Ülkemizde fotovoltaik sistemlerin kullanımını yaygınlaştırmak amacıyla, 5346 sayılı “Yenilenebilir Enerji Kaynakları Kanunu” 29.12.2010 yılında revize edilmiş ve 2013’te mevzuat çalışmaları tamamlanmıştır. Son yıllarda fotovoltaik sistemlerin maliyetlerin düşürülmesi ve verimliliğin artması sayesinde de kullanımının artması beklenmektedir. Enerji ve Tabii Kaynaklar Bakanlığının verilerine göre ülkemizde 2016 yılı sonu itibarıyla kurulu gücü 402 MW olan 34 adet güneş enerjisi santraline ön lisans, kurulu gücü 12.9 MW olan 2 adet güneş enerjisi santraline lisans verilmiştir. Lisanssız elektrik üretim santrallerinin kurulmasıyla birlikte 2016 yılı sonu itibarıyla güneş enerjili santral sayısı 1043 olarak görülürken bu santrallerin kurulu gücü ise 819.6 MW olup 2 adet lisanslı güneş enerjisi santrali ile birlikte toplam kurulu gücü 832.5 MW’a ulaşmıştır.

3. MAKSİMUM GÜÇ NOKTASI İZLEME

Güneş enerjisi, fotovoltaik (PV) paneller kullanılarak DC elektrik enerjisine dönüştürülebilse de bu panellerin üretim maliyetleri yüksek, enerji dönüşüm verimleri de düşüktür. Üretim aşamasında PV panel yapımında farklı özelliklere sahip yarı iletken malzemeler kullanılarak panel verimi artırılabilir. Ancak bu yolla verim % 10-15 seviyelerinden henüz % 30-35 seviyelerine getirilebilmektedir.


PV panellerden daha fazla güç elde etmek ve yatırımdan en yüksek faydayı sağlamak amacıyla geliştirilen bir diğer yol ise güneşin pozisyonu takip edilerek güneş ışınlarının PV modül üzerine dik açı (90°) ile düşmesini sağlamaktır. Böylece gün içinde güneş enerjisinden daha fazla faydalanılabilir ve enerji dönüşüm verimi artırılabilir [69].

Bununla birlikte PV sistemlerde panelin ürettiği çıkış gücü, güneş ışınımı seviyesi ve panelin sıcaklığı gibi farklı parametrelere bağlı olarak da değişmektedir. Bu nedenle PV paneller, sabit ışınım ve sıcaklık koşulları altında doğrusal olmayan Akım-Gerilim (I-V) ve Güç-Gerilim (P-V) karakteristiği göstermektedirler. Belirli atmosferik koşullar altında belirli bir yükü besleyen bir PV panel için tek bir maksimum güç değeri bulunmaktadır. Panelin sürekli bu güç değerinde çalışması sağlanarak güneş enerjisi üretim sisteminin verimi artırılabilir. Bu gereksinimlerden dolayı PV panellerin besledikleri sistemlere maksimum güç aktarabilmeleri için geliştirilen yöntemle Maksimum Güç Noktası İzleme (MPPT) yöntemi denilmektedir.

Bu yöntemin temel amacı, değişen şartlar altında panelden elde edilebilecek maksimum güç noktasını daima takip ederek fotovoltaik sistemi bu noktada çalıştırmak ve maksimize edilmiş gücü yüke veya depolama sistemine aktarmaktır [70].

PV sistemlerin MPP'de çalışması, paneller ile beslenen sistem/sistemler arasında ara yüz oluşturan dönüştürücülerin uygun biçimde denetlenmesi ile sağlanabilir. Böylece, panel çalışma noktası değişen ışınım, sıcaklık, yük gibi parametrelere göre sürekli denetlenerek yüke her an üretilebilen maksimum gücün aktarımı sağlanabilir. MPPT sistemleri PV panelden elde edilen gerilim ve akım değerlerini sürekli izler ve bir algoritma yapısı ile dönüştürücüye uygun sinyali göndererek PV sistemdeki maksimum güç akışını kontrol ederler. PV sistemlerde MPP takibi genellikle bir DC-DC dönüştürücü ile yapılırsa da yükün AC olduğu sistemlerde hem DC-AC dönüşümün hem de MPP takibi işleminin aynı evirici devresinde gerçekleştirildiği tek aşamalı sistemler de mevcuttur.

Şekil 3.1’de MPP kontrolü yapılan bir PV sistemin blok diyagramı görülmektedir. Burada bir MPPT kontrol ünitesi ile birlikte, PV panel çıkışı ile yük arasında güç akış kontrolünü sağlamak ve PV panelin, maksimum güç noktasının izlenmesi amacıyla DC-DC anahtarlama bir güç dönüştürücüsü kullanılmıştır. Bu iki ünite bir arada maksimum güç noktası izleme sistemini oluştururlar [71].



Şekil 3.1. MPPT kontrollü bir PV sistemin blok diyagramı

Şekil 3.1’de verilen sistemde, MPPT kontrol cihazı MPP’yi bulmak için algoritmayı çalıştırır. Kontrolörün girişi güneş panelinin ölçülen çıkış gerilimi ve akımıdır. Kontrolörün çıkışı, DC-DC dönüştürücünün anahtarlama cihazını çalıştıran darbe genişlik modülasyonunun ayarlanmış görev oranı (D)’dır. Bir darbe genişlik modülasyonu sinyalinin görev oranı, dönüştürücünün giriş ve çıkış voltajı arasındaki oranı belirler. Farklı bir görev oranı, farklı bir çalışma noktasına neden olur. Bu hesaplamalara ek olarak, denetleyici ayrıca ölçülen çıkış voltajını ve akımını içerisinde bulunan işletim sistemine gönderir. Bu değerler, ne kadar enerji üretildiğini izlemek ve sistemdeki hataları veya değişimleri tespit etmek için kullanılır. Netice itibari ile Maksimum güç noktası takibi, maksimum güç noktası izleme (MPPT) algoritmaları ile dönüştürücünün görev oranı (D) kontrol edilerek yapılır [72].

3.1. Maksimum Güç Noktası İzleme İçin Algoritmalar

PV sistemlerden her zaman maksimum gücün elde edilebilmesi için Maksimum Güç Noktası İzleme (MPPT) sistemlerinde bulunan dönüştürücü devresinin panel çıkışına göre yük gerilimini ayarlaması ve daima PV sistemi maksimum güç noktasında tutması istenmektedir. Dönüştürücünün maksimum güç noktasını en iyi şekilde takip edebilmesi

kullanılan MPPT yöntemine bağılı olarak deęiřmektedir. MPPT yöntemleri iin literatürde uygulama zorluęu, maliyet, mikroiřlemci kullanımı, karmařıklık ve maksimum güç noktasını izleme başarımı gibi kriterlere göre doğrudan ve dolaylı yöntemler geliştirilmiřtir.

Doğrudan yöntemler kullanılarak gerekleřtirilen MPPT, PV panellerin karakteristik özelliklerinin dikkate alınmadıęı, panelden bağımsız olarak panel ve/veya dönüřtürücü devresinin ıkıř akımı, gerilimi veya gücü gibi parametrelerinin sürekli olarak takip edilmesi ile gerekleřtirilir. Doğrudan yöntemler panelden bağımsız olarak MPPT gerekleřtirdięi iin dolaylı yöntemlere göre daha ok tercih edilir.

Dolaylı yöntemler ise ıřınım seviyesi, panel sıcaklıęı, kısa-devre akımı, açık-devre gerilimi ve panel ile ilgili dięer bazı parametrelerin doğrudan veya matematiksel eřitliklerden faydalanılarak tahmin edilmesine dayanmaktadır [69]. Kullanılan parametreler seilen panel iin önceden hesaplanır ve elde edilen parametreler kullanılarak MPP tespit edilmeye alıřılır. Bu yöntemlerin uygulanmaları basit olsa da, panelin yařlanmasına bağılı olarak zamanla karakteristik özelliklerinin deęiřebilmesi, önceden belirlenen parametrelerin gerek sonuçlar vermemesi gibi nedenlerden dolayı MPPT iřlemi tam olarak yapılamayabilir [73, 74].


Uygulamada deęiřtir-gözle, artan-iletkenlik, bulanık mantık denetim, yapay sinir aęları, bakma tablosu, pilot hücrenin kullanılması, sabit akım yöntemi, sabit gerilim yöntemi, sadece akım ve gerilim yöntemi, parazitik kapasitans, dalgalanma korelasyon kontrol yöntemi gibi bazı MPPT yöntemleri önerilmiřtir. Bu bölümde, literatürde en ok karřılařılan beř MPPT algoritması sırasıyla açıklanmıřtır. Bunlar, doğrudan yöntemler olarak adlandırılan sınıfta yer alan; deęiřtir-gözle yöntemi, artan iletkenlik algoritması ve bulanık mantık denetim yöntemi ile birlikte dolaylı yöntemler olarak adlandırılan sınıfta yer alan; sabit gerilim yöntemi ve sabit akım yöntemidir.

3.1.1. Deęiřtir - Gözle Yöntemi

Kullanılan en yaygın MPPT algoritmaları ierisinde yer alan deęiřtir-gözle yöntemi, PV panellerin alıřma noktasının deęiřtirilmesi neticesinde meydana gelecek olan deęiřimin gözlenmesi ve böylece maksimum güç noktasına doğru sonraki deęiřimin belirlenmesi prensibine dayanır. Deęiřtir-gözle yöntemi basit yapısı ve kolay bir řekilde uygulanabilmesinden dolayı yaygın olarak kullanılmaktadır. řekil 3.2’de görüldüęü gibi bu yöntemde PV panellerin ıkıř gerilimi izlenir. Eęer $\frac{dP}{dV} > 0$ ise, alıřma noktası maksimum güç noktasının solundadır. Bu durumda deęiřtir-gözle yöntemi, PV panel referans gerilimini


maksimum güç noktasına doğru artırır. Eğer $\frac{dP}{dV} < 0$ ise, çalışma noktası maksimum güç noktasının sağındadır ve PV panelin referans gerilimi azaltılır [65].

Burada PV panel çıkış gerilimi, kontrol değişkeni olarak kullanılmaktadır. Şekil 3.3'de verilen akış diyagramında da görüldüğü gibi, ilk olarak panel gerilimi ve panel akımı ölçülür ve panellerin çıkış gücü hesaplanır. Eğer PV panel gerilimindeki artışla beraber PV panel çıkış gücü de artıyor ise, referans gerilim artırılır. Aksi halde, yani PV panel çıkış gücü gerilim azalırken artıyor ise referans gerilim azaltılır. Eğer panellerin çıkış gücü, gerilimdeki artışla birlikte azalıyor ise, referans gerilim azaltılır. Aksi halde, referans gerilim artırılır. Değiştir-gözle yönteminde güç artıyorsa, izleme sonraki çevrimde aynı yönde, aksi durumda ters yönde devam eder. Bu nedenle bu yöntem “tepe-tırmanma” algoritması olarak da bilinir. Böylece, farklı ışık şiddeti ve sıcaklık değerleri için PV panellerin çalışma noktası maksimum güç noktasına doğru taşınabilir.



Şekil 3.2. P_{PV} - V_{PV} karakteristiğinde çalışma bölgeleri


Değiştir-gözle yönteminin dezavantajlarından birisi maksimum güç noktası etrafında salınımlar oluşturmalarıdır. Salınımlar, kontrol edilen parametre için kullanılan adım büyüklüğünün azaltılmasıyla minimize edilebilir. Ancak daha düşük adım büyüklüğü maksimum güç noktası izlemeyi yavaşlatabilir. Bu problem için çözüm yollarından birisi, değişken bir adım büyüklüğünün kullanılmasıdır [62].



Şekil 3.3. Değiştir&Gözle (D&G) algoritması akış diyagramı [66]

3.1.2. Artan İletkenlik Yöntemi

Şekil 3.4'te artan iletkenlik yöntemi çalışma koşuluna ait grafik verilmiştir. Artan iletkenlik yönteminin temeli PV panel çıkış gücü eğiminin sıfır olduğu yeri maksimum güç noktası (MPP), pozitif olduğu yeri MP noktasının solu, negatif olduğu yeri MP noktasının sağı olarak belirlemesine dayanır [74].



Şekil 3.4. Artan İletkenlik algoritması çalışma eğrisi [54]

Şekil 3.4'te verilen eğri artan iletkenlik algoritmasının temelini oluşturur. Bu eğriden yararlanılarak aşağıdaki denklemler yazılabilir.

$$\begin{aligned}
 dP / dV = 0 &\Rightarrow \text{MP noktasında,} \\
 dP / dV > 0 &\Rightarrow \text{MP noktasının solunda,} \\
 dP / dV < 0 &\Rightarrow \text{MP sağında,}
 \end{aligned} \tag{3.1}$$

Denklem 3.1 yardımı ile denklem 3.2 yazılabilir:

$$\frac{dP}{dV} = \frac{d(IV)}{dV} = I + V \frac{dI}{dV} = I + V \frac{\Delta I}{\Delta V} \tag{3.2}$$


Denklem 3.2 yeniden düzenlenirse:

$$\begin{aligned}
 \Delta I / \Delta V = -I / V &\Rightarrow \text{MP noktasında,} \\
 \Delta I / \Delta V > -I / V &\Rightarrow \text{MP noktasının solunda,} \\
 \Delta I / \Delta V < -I / V &\Rightarrow \text{MP noktasının sağında,}
 \end{aligned} \tag{3.3}$$

Eşitlikleri elde edilir [75].

Denklem 3.3'te, $-I / V$ ifadesi PV panelin ani iletkenlik değerinin tersini ifade etmektedir. $\Delta I / \Delta V$ ifadesi ise artan iletkenlik değeridir. Bu durumda maksimum güç noktasında bu iki değer birbirine eşit fakat zıt işaretli olması gerekir. Bu denklemde bir eşitsizlik olması halinde çalışma geriliminin MPP geriliminden düşük ya da yüksek olduğu anlaşılır. Bu

yöntemde de değiştir-gözle yönteminde olduğu gibi çıkış akımı ve gerilim gözlemlenir. Artan iletkenlik algoritması ani iletkenliği ve artan iletkenliği hesaplar ve buna göre maksimum güç noktasına ulaşana kadar referans gerilimi (veya akımı) artırır veya azaltır. Artan iletkenlik algoritmasına ait akış diyagramı Şekil 3.5’de görülmektedir. Artan iletkenlik metodunun en önemli avantajı hızlı değişen atmosferik koşullara uyum sağlayabilmesi ve MP noktasında meydana gelen salınım değiştir – gözle yönteminden çok daha az olmasıdır. Önceleri hesap işlemleri fazla zaman aldığından tepki hızları yavaş idi. Günümüzde ise dijital teknolojilerin hızlı gelişimi bu olumsuz etkiyi kaldırmış durumdadır. Ancak artan iletkenlik yöntemi ile kontrol edilen devreler biraz daha karmaşık ve pahalıdır [74, 75].



Şekil 3.5. Artan iletkenlik algoritması akış diyagramı

3.1.3. Sabit Gerilim Yöntemi


Sabit gerilim veya diğer adı ile açık devre gerilim yöntemi, PV panellerden maksimum gücün elde edildiği çalışma noktasının açık devre geriliminin sabit bir yüzdesine karşılık gelmesi prensibine dayanır. Bu yöntemde PV panellerin akımı kısa bir süre sıfır yapılarak panellerin açık devre gerilimi ölçülür. Alternatif olarak panellerin açık devre geriliminin ölçülmesi için ek bir PV panel de kullanılabilir. Araştırmalar V_{MPP} geriliminin V_{oc} geriliminin doğrusal bir fonksiyonu olduğunu göstermektedir. Bu değer üretim tekniği, çevresel koşullar gibi etkenlere bağlı olarak polikristal modüllerde ortalama V_{oc} geriliminin % 73-80'i civarındadır [47]. Daha genel bir ifade ile,

$$k_1 = \frac{V_{MPP}}{V_{oc}} \cong \text{sabit} \quad (3.4)$$

olarak ifade edilebilir. Burada k_1 sabiti değişmediğinden MPP gerilimi (V_{MPP}) açık devre gerilimi (V_{oc}) yardımı ile kolaylıkla bulunabilir. Örneklememe işlemi çıkış yükü devrede değilken V_{oc} geriliminin okunması ile gerçekleşir. Sık örneklememe MPPT işleminin hassas bir şekilde sürdürülmesini, dolayısı ile hata oranını azaltacaktır.

Sabit gerilim metodu oldukça basit, karmaşık devreler gerektirmeyen, ucuz ve kullanışlı bir yöntemdir. Ancak referans işareti oluşturabilmek için gerekli olan V_{oc} gerilim bilgisini okuyabilmek için PV modülden yükü ayırma ihtiyacının yükler için sorun teşkil etmesi ve bu sırada güneş enerjisinden yararlanılamaması, gerçek MPPT işleminin sürdürülememesi olumsuz etkileridir.

Sistem güvenilirliği ve yüklerin devreden çıkarılmasını önlemek amacı ile aynı özellikte bir hücre örneklememe elemanı olarak kullanan sistemler de mevcuttur. Bu durumda bir hücre sürekli devre dışı kalmaktadır. Şekil 3.6'da sabit gerilim yöntemine ait akış diyagramı verilmiştir [47].



Şekil 3.6. Sabit gerilim metodu akış diyagramı

3.1.4. Sabit Akım Yöntemi

Sabit akım veya diğer adıyla kısa devre akım yöntemi sabit gerilim yöntemine çok benzeyen bir yöntemdir. Bu yöntemde PV panelin maksimum güç noktası akımı (I_{MPP}), kısa devre akımı (I_{sc}) ile orantısal bir ilişki içerisinde. Bu değer üretim tekniği ve çevresel koşullara bağlı olarak değişmekle birlikte % 85’ler civarındadır. Kısa devre akımı ile MPP akımı arasındaki orantısal k_2 sabiti sıcaklık ve ışınım değişikliğinde korunur. Kısa devre akımı ile MPP akımı arasındaki bağıntı denklem 3.5 ile ifade edilebilir.

$$I_{MPP} = k_2 \cdot I_{SC} \quad (3.5)$$


Denklem 3.5 kullanılarak MPP akımı kısa devre akımının ölçülmesi ile bulunur ve denklem 3.6’daki akım denetimli dönüştürücünün referans işareti oluşturulur.

$$I_{REF} = I_{MPP} \quad (3.6)$$

Kısa devre akım metodu basit ve karmaşık devreler gerektirmeyen yapıda olmasına rağmen kısa devre akımının ölçülmesi gerekliliği, bu esnada enerji kaybı, k_2 sabiti belirleme işlemi ve panel yüzeyinde meydana gelebilecek kirlilik v.b. sebeplerden kaynaklanan k_2 sabiti sapmaları bu yöntemin olumsuz etkilerindendir. Sistem akış diyagramı ise sabit gerilim metodunda olduğu gibidir [47].

3.1.5. Bulanık Mantık Denetim Yöntemi

Bulanık mantık denetim son zamanlarda PV sistemlerde maksimum güç noktası takibi için yaygın olarak kullanılan ve uzman bilgisinden gelen sezgisel bilgilerden lineer olmayan kontrolörlerin oluşturulmasını sağlayan bir yöntemdir. Bu yöntem güçlü ve diğer geleneksel yöntemlere nazaran tasarlanması basittir. Bunun sebebi tam modelleme bilgisine ihtiyaç duymamasıdır. Ancak diğer taraftan, PV sisteminin işleyişi ile ilgili tasarımcının tam bilgiye sahip olması gerekir. Bulanık bir kontrolörün blok diyagramı Şekil 3.7'de gösterilmiştir [83].



Şekil 3.7. Bulanık Mantık Denetimi Blok diyagramı

Bir bulanık mantık denetim algoritmasında; bulanıklaştırma, çıkarım ünitesi ve bulanıklaştırmayı sona erdiren durulaştırma gibi üç ayrı durum söz konusudur. Bulanık mantık kontrolörü PV kaynak çıkışından alınan anlık akım ve gerilim değerlerini sürekli olarak ölçer ve denetleyicinin girişlerini elde etmek için PV gücünü hesaplar. Elde edilen bu değerler yardımıyla bulanıklaştırma periyodunda bir hata fonksiyonu ve hata değişimi meydana getirilir. İlk olarak hata $E(k)$ ve hata değişim fonksiyonu $C(k)$ hesaplanır. Bu değişkenler sistemin giriş değişkenlerini oluşturur. Ayrıca bu periyotta bulanıklaştırma girişine uygulanan bu kesin girişler bulanıklaştırılır ve çıkarım ünitesine iletilir. Çıkarım ünitesinde bulanıklaştırma ünitesinin çıkışları ve kural tabanı kullanılarak Tablo 3.1.'deki kurallar tablosu yardımıyla bulanıklaştırma ünitesinden alınan bilgiler işlenir ve sistemin vereceği uygun cevaplar tanımlanır. Bulanıklaştırmayı sona erdiren durulaştırma periyodunda ise sistemin verdiği cevap değişkenleri sonuçlara (net çıktıya) dönüştürülür. Kontrolörün net çıkışı dönüştürücünün görev oranıdır. Dönüştürücüye uygulanacak sinyalin darbe genişlik modülasyonu bu orana göre belirlenir.


$E(k)$ hatası, gerilimdeki değişime göre güçte değişiklik olarak ayarlanır ve şu şekilde ifade edilir:

$$E(k) = \frac{P_{pv}(k) - P_{pv}(k-1)}{V_{pv}(k) - V_{pv}(k-1)} \quad (3.7)$$

Hata değişim fonksiyonu olan $C(k)$ ise;

$$C(k) = E(k) - E(k-1) \quad (3.8)$$

Burada, $P_{pv}(k)$ PV kaynağın anlık gücüdür. Giriş $E(k)$ yük çalışma noktasının P-V karakteristiği üzerinde, maksimum güç noktasının sağ veya sol tarafında konumlanıp konumlanmadığını gösterirken, giriş $CE(k)$ bu noktanın hareket yönünü ifade eder [83,84]. Bulanık mantıkla kontrolde, sayısal giriş değişkenleri bulanıklaştırma ünitesinde şekil 3.8.'de gösterildiği gibi üyelik fonksiyonlarına bağlı olarak dilsel değişkenlere dönüştürülür. Bu çalışmada, tüm girdi ve çıktı değişkenleri için beş bulanık seviye kullanılmıştır. Bunlar: NB (negatif büyük), NS (negatif küçük), ZE (sıfır), PS (pozitif küçük) ve PB (pozitif büyük) şeklindedir. Kullanıcının tercihinine göre kontrol hassasiyetini iyileştirmek için bu seviye sayısı: NB (negatif büyük), NM (negatif orta), NS (negatif küçük), ZE (sıfır), PS (pozitif küçük), PM (pozitif orta) ve PB (pozitif büyük) olmak üzere yedi bulanık seviye olarak da seçilebilir [85].



Şekil 3.8. (a)Hata (E) girişi için üyelik fonksiyonu, (b)Hatadaki değişim (CE) girişi için üyelik fonksiyonu, (c) Görev oranı (D) çıkışı için üyelik fonksiyonu

Tablo 3.1.'de ise Bulanık Mantık denetimi için Kural tabanı verilmiştir. Bulanık kontrolörün yapısında bulunan bulanık kural tabanı, sistemde denetlenen parametreler için tüm bilgileri içeren if-then kurallarının bir toplamıdır. Profesyonel deneyime ve sistem kontrolünün çalışmasına göre ayarlanır. Bulanık kural tabanı, Tablo 3.1.'de listelenen 25 bulanık kontrol kuralını içerir. Bu kuralların işlenmesi ise bulanık çıkarım ünitesinde yapılır. Bulanık çıkarım ünitesi, bulanık kural ayarına dayalı mantıksal bir karar formüle eden ve bulanık kural tabanını bulanık dilsel çıktıya dönüştüren bir işletim yöntemidir. Bu çalışmada, Mamdani'nin bulanık çıkarım yöntemi kullanılmıştır [86].

Tablo 3.1. Bulanık Mantık Denetimi İçin Kural Tabanı

$E \searrow CE \rightarrow$	NB	NS	ZE	PS	PB
NB	ZE	ZE	PB	PB	PB
NS	ZE	ZE	PS	PS	PS
ZE	PS	ZE	ZE	ZE	NS
PS	NS	NS	NS	ZE	ZE
PB	NB	NB	NB	ZE	ZE

3.1.6. Geleneksel MPPT Algoritmalarını İçeren Çalışmalar

Literatürde sunulan birçok PV güç sisteminde maksimum güç noktası izleme (MPPT) metodu kullanılmıştır. Aşağıda geleneksel MPPT algoritmalarını içeren bazı önemli çalışmalar özet olarak verilmiştir.

Ref. [76], PV panellerin eşdeğer devre parametrelerinin bulunması ve PV sistemin en uygun çalışmasına uygulanması hakkında bir metot sunulmuştur. Ayrıca bu çalışmada eşdeğer parametreler, ölçüm değerleri kullanılarak eğri uydurma metoduyla hesaplanmıştır. Model parametreleri kullanılarak yeni bir MPPT yöntemi gösterilmiş, çalışmada diğer MPPT metotlarına göre karşılaştırmalar simülasyon ortamında yapılmıştır.

Ref. [77], değiştir – gözle yöntemini kullanan gerçek zamanlı bir maksimum güç noktası izleyici gerçekleştirerek PV sistemin enerji dönüşüm veriminin artırılmasını hedeflemiştir. MPPT algoritması, PV panel gerilim ve akım bilgisi kullanılarak gerçekleştirilmiş ve gerilim yükseltici (boost) dönüştürücünün bağıl iletim süresi, darbe genişlik modülasyonu metoduyla kontrol edilmiştir. Yöntemin temel avantajları güneş paneli karakteristiklerinin bilinmesini gerektirmemesi ve referans PV panel kullanımına gerek olmamasıdır.

Ref. [78], MPPT algoritmalarını ve optimize edilmiş MPPT algoritmalarını kullanarak her iki durumda da çıkış gücünün varyasyonunu göstermek için iki farklı güneş ışıını fonksiyonunu kullanarak maksimum güç noktası izleme için yedi farklı algoritmayı karşılaştırmıştır.

Ref. [79]'da güneş ışıını dikkate alarak yeni bir maksimum güç noktası izleme (MPPT) kontrol algoritması önerilmiştir. Önerilen algoritma değiştir ve gözle (D&G) yöntemini ve sabit gerilim (CV) yöntemini içermektedir. Güneş ışıını düşük olduğu durumlarda, sabit gerilim (CV) kontrol yöntemi uygulanırken, güneş ışıını yüksek

olduđu durumlarda D&G kontrol yöntemi uygulanmıřtır. Önerilen algoritma geleneksel MPPT algoritmaları ile karşılaştırılmıřtır.

Ref. [80]'de güneř ıřınlarından mümkün olan maksimum gücü sağlamak için güneřin eğiminin deęişimini dikkate alınan bir çalışma yapmıřlardır. Çalışmada kontrol mekanizması, panelin pozisyonunu, gelen güneř ıřınımlarının panellere her zaman dik olarak gelmesini sağlayacak şekilde deęiřtirmektedir.

Ref. [81]'de fotovoltaik güç kontrolü alanında SEPIC dönüřtürücünün kullanımı hakkında ayrıntılı bir çalışma yapılmıřtır. Çalışmasında, güneř hücresinden maksimum güç çıkarımını gerçekleřtirmek için iki giriřli bir dönüřtürücü kullanmıřtır.

Ref. [82]'de fotovoltaik modüllerde kullanılan artan iletkenlik (IC) maksimum güç noktası izleme algoritmasının davranıřını ayrıntılı bir şekilde analiz edilmiřtir.

4. UÇ ÖĞRENME MAKİNESİ

İleri beslemeli sinir ağlarının öğrenme hızının genel olarak gerekenden çok daha yavaş olduğu ve son on yıldaki uygulamalarında büyük bir darboğaz olduğu açıktır. Bunun iki sebebi vardır:

- 1) Bu ağların eğitiminde yaygın olarak kullanılan eğitim tabanlı öğrenme algoritmalarının yavaş olması,
- 2) Ağların tüm parametreleri, bu öğrenme algoritması ile yinelenerek ayarlanmasıdır.

Bu geleneksel eğitim algoritmalarının aksine, giriş ağırlıklarını rastgele seçen ve tek gizli katmanlı sinir ağının (SLFN) çıkış ağırlıklarını analitik olarak belirleyen uç öğrenme makinesi (UÖM) adı verilen yeni bir öğrenme algoritması G. B. Huang tarafından önerilmiştir [43]. Teoride, bu algoritma son derece yüksek öğrenme hızında en iyi genelleme performansını sağlamaktadır. Gerçek dünya karşılaştırmalı değerlendirme fonksiyonu kestirimi ve büyük karmaşık uygulamaları içeren sınıflandırma problemlerine dayanan deneysel sonuçlar, yeni algoritmanın, bazı durumlarda en iyi genelleme performansını sağlayabileceğini ve ileriye dönük sinir ağları için geleneksel popüler öğrenme algoritmalarından çok daha hızlı öğrenebileceğini göstermiştir.

Matematiksel bakış açısından, ileri beslemeli sinir ağlarının yaklaşım yetenekleri üzerine yapılan araştırmalar giriş kümelerinde evrensel yaklaşım ve sonlu küme (set) yaklaşımı olmak üzere iki konuya odaklanmıştır. Birçok araştırmacı, standart çok katmanlı ileri beslemeli sinir ağlarının evrensel yaklaşım yeteneklerini araştırmıştır [87-89]. Gerçek uygulamalarda, sinir ağları sonlu eğitim kümesi kullanılarak eğitilmiştir. Sonlu bir eğitim kümesinde fonksiyon yaklaşımı için, Huang ve Babri [90], en fazla N gizli nöronuna sahip olan ve neredeyse tüm doğrusal olmayan aktivasyon fonksiyonlarına sahip, bir SLFN'nin sıfır hata ile N farklı gözlemleri öğrenebileceğini göstermiştir. Giriş ağırlıklarının (giriş katmanını ilk gizli katmana bağlar) önceki tüm teorik araştırma çalışmalarında ve ileri beslemeli sinir ağlarının neredeyse tüm pratik öğrenme algoritmalarında ayarlanması gerektiği belirtilmelidir. Geleneksel olarak, ileri beslemeli ağların tüm parametrelerinin ayarlanması gerekir ve bu yüzden farklı parametre katmanları birbiri ile ilişkilidir. Geçtiğimiz on yıllar boyunca, eğitim düşünüm tabanlı yöntemler, temelde ileri beslemeli sinir ağlarının çeşitli öğrenme algoritmalarında kullanılmıştır. Ancak, eğitim düşünüm tabanlı öğrenme yöntemlerinin uygun olmayan öğrenme adımları nedeniyle genellikle çok yavaş

olduğu ya da kolayca yerel minimumlara (en düşük değerlere) yaklaşabileceği açıktır. Daha iyi bir öğrenme performansı elde etmek için birçok yinelemeli öğrenme aşaması, bu tür öğrenme algoritmaları tarafından istenmektedir. Bu tür öğrenme algoritmaları daha iyi bir öğrenme performansı elde etmek için birçok tekrarlı öğrenme aşaması, gerektirmektedir. Gelişi güzel olarak seçilen girdi ağırlıklarına sahip SLFN'lerin (N gizli nöronlu) gelişi güzel küçük bir hatayla N farklı gözlemleri öğrenebileceği gösterilmiştir [91,92]. İleri beslemeli ağların tüm parametrelerinin ayarlanmasını gerektiren eğim düşüm algoritması ve pratik uygulamaların aksine, uygulamalardaki giriş ağırlıklarını ve ilk gizli katman biaslarının ayarlaması gerekmebilir. Esasında, çalışmada yapay ve gerçek büyük uygulamalara ilişkin bazı benzetim sonuçları bu yöntemin öğrenmeyi sadece son derece hızlı hale getirmekle kalmayıp aynı zamanda iyi bir genelleme performansı da ürettiğini göstermiştir [93].

Ref. [94]'te yapılan bir çalışmada, rastgele atanmış giriş ağırlıkları ve gizli katman biasları olan ve sıfır olmayan bir aktivasyon fonksiyonuna sahip SLFN'lerin, herhangi bir giriş kümesinde herhangi bir sürekli fonksiyonu global minimuma yaklaştıracak şekilde kanıtlanmıştır. Bu araştırma sonuçları, ileri beslemeli sinir ağlarının uygulamalarında giriş ağırlıklarının mutlaka ayarlanması gerekmediğini göstermiştir. Giriş ağırlıkları ve gizli katman biasları rastgele seçildikten sonra, SLFN'ler doğrusal bir sistem olarak kabul edilebilir ve SLFN'lerin çıkış ağırlıkları (gizli katmanı çıkış katmanına bağlayan), gizli katman çıkış matrislerinin basit genelleştirilmiş ters işlemiyle analitik olarak belirlenebilir. Bu konseptte dayanarak öğrenme hızı geri yayılım algoritması gibi geleneksel ileri beslemeli ağı öğrenme algoritmalarından binlerce kat daha hızlı olabilen ve daha iyi genelleme performansı elde eden geleneksel ileri beslemeli ağı öğrenme algoritmalarından daha hızlı olabilen Uç Öğrenme Makinesi (UÖM) olarak adlandırılan SLFN'ler için basit bir öğrenme algoritması G. B. Huang tarafından önerilmiştir [43].

Geleneksel öğrenme algoritmalarından farklı olarak, önerilen öğrenme algoritması sadece en küçük eğitim hatasına değil, aynı zamanda en küçük ağırlık normuna da ulaşma eğilimindedir. Ref. [95]'te Bartlett'in ileri beslemeli sinir ağlarının genelleme performansı konusundaki teorisi ileri beslemeli sinir ağlarının daha küçük bir eğitim hatasına ulaşması için, ağırlıkların normları ne kadar küçükse, o kadar iyi bir genelleme performansına sahip olma eğilimleri olduğunu belirtir. Bu nedenle, önerilen öğrenme algoritması ileri beslemeli sinir ağları için daha iyi genelleme performansına sahip olma eğilimindedir. Önerilen yeni öğrenme algoritması en küçük eğitim hatasına ulaşma, en küçük ağırlık normunu ve en iyi genelleme performansını elde etme eğiliminde olduğundan son derece hızlı çalışmaktadır.

UÖM'nin matematiksel temellerinden önce bir matrisin Moore-Penrose genelleştirilmiş tersine değinmek faydalı olacaktır. Ayrıca, bu bölümde, $A \in R^{m \times n}$ ve $y \in R^m$ olduğu Öklid uzayında genel bir doğrusal sistemin $Ax = y$ minimum karesel çözümü göz önünde bulundurulmalıdır. [91,92] 'de belirtildiği gibi, eğer giriş ağırlıkları ve gizli katman biasları keyfi olarak seçilebiliyorsa SLFN'ler aslında doğrusal sistemlerdir.

A'nın tekil olabileceği ve hatta kare olamayacağı genel bir lineer sistemin $Ax = y$ çözümü Moore-Penrose genelleştirilmiş tersi kullanılarak çok basit hale getirilebilir [96].

$n \times m$ boyutunda bir G matrisi, $m \times n$ boyutunda A matrisinin genelleştirilmiş tersi Moore-Penrose'dur ve ilgili işlemler aşağıdaki denklemde gösterilmiştir.

$$AGA=A, GAG=G, (AG)^T=AG, (GA)^T=GA \quad (4.1)$$

A matrisinin Moore-Penrose genelleştirilmiş ters matrisi $A^\dagger$ olarak belirtilecektir.

$Ax = y$ doğrusal bir sistem için, $\|\cdot\|$ Öklid uzayında bir norm olmak üzere eğer $\|A\hat{x} - y\| = \min_x \|Ax - y\|$ ise $\hat{x}$ en küçük kareler çözümüdür. Herhangi bir $y \in R^m$ nin $\|x_0\| \leq \|x\|$, $\forall x \in \{x: \|Ax - y\| \leq \|Az - y\|, \forall z \in R^n\}$ için $x_0 \in R^n$ 'nin $Ax = y$ doğrusal sisteminin minimum norm en küçük kareler çözümü olduğu söylenir. Bunun anlamı, en küçük kareler çözümlerinin tümünün arasında en küçük norma sahip ise x_0 çözümü $Ax = y$ doğrusal sisteminin en küçük kareler çözümüdür. G_y 'nin $Ax = y$ doğrusal sisteminin en küçük kareler çözümü olduğu durumda bir G matrisi olsun. Bu durumda Moore-Penrose, A matrisinin genelleştirilmiş tersinin $G = A^\dagger$ olması zorunlu ve yeterlidir.

Yukarıda anlatılanlara bağlı olarak $\tilde{N}$ gizli nöronları olan tek gizli katman ileri besleme ağları (SLFN'ler) için son derece hızlı bir öğrenme algoritması G. B Huang tarafından önerilmiştir [43]. Burada $\tilde{N} \leq N$ öğrenme örneklerinin sayısıdır.

N rasgele farklı örnekler için (x_i, t_i) , burada $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ ve $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$, standart $\tilde{N}$ gizli hücreye ve $g(x)$ aktivasyon fonksiyonuna sahip bir SLFN'nin çıkışı matematiksel olarak aşağıdaki gibi yazılabilir.

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = o_j, \quad j = 1, \dots, N, \quad (4.2)$$

Burada,

$w_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T$, gizli hücreyi ve giriş hücresine bağlayan ağırlık vektörü, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$, gizli hücreyi ve çıkış hücresine bağlayan ağırlık vektörü ve b_i , i . gizli hücrenin bias değeridir. Ayrıca $w_i \cdot x_j$, w_i ve x_j 'nin iç çarpımını belirtir. Bu tez çalışmasında çıkış hücresi doğrusal seçilmiştir. Aktivasyon fonksiyonu $g(x)$ olan $\tilde{N}$ gizli hücreye sahip standart bir SLFN'nin bu N tane örneği sıfır hatayla yaklaştırabileceği anlamına gelir. Yani,

$$\sum_{j=1}^{\tilde{N}} \|o_j - t_j\| = 0,$$

eşitliğini sağlayan β_i , w_i ve b_i 'ler vardır. Denklemden, o_j SLFN'nin çıkışı ve t_j ise hedef çıkışlardır. Bu durumda $o_j = t_j$ olmalıdır.

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = t_j, j = 1, \dots, N. \quad (4.3)$$

Yukarıdaki N denklemleri aşağıdaki gibi sade şekilde yazılabilir.

$$H\beta = T \quad (4.4)$$

Burada

$$H(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}}, x_1, \dots, x_N) \quad (4.5)$$

=

$$\begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m} \quad \text{ve} \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (4.6)$$

Burada H sinir ağının gizli katman çıkış matrisidir. H 'ın i . sütunu, sırasıyla $x_1, x_2, \dots, x_N$ girişleri için i . gizli nöronun çıkış vektörüdür.

4.1. Eğim Tabanlı Öğrenme Algoritmaları

Bir SLFN'nin gizli hücre sayısı farklı eğitim örneklerinin sayısına eşit ($\tilde{N} = N$) ve $\mathbf{H}$ matrisi kare matris ise SLFN'ler bu eğitim örnekleri değerlerine sıfır hata ile yaklaşabilir. Bununla birlikte, çoğu durumda, gizli hücre sayısı, farklı eğitim örneklerinin sayısından çok daha azdır. $\tilde{N} \ll N$ ve $\mathbf{H}$ matrisi kare olmayan bir matris olur. Bu durumda, w_i, b_i, β_i ($i=1, \dots, \tilde{N}$) bulunamayabilir ve $\hat{w}_i, \hat{b}_i, \hat{\beta}_i$ ($i=1, \dots, \tilde{N}$) değerlerinin bulunması gerekebilir. Bu durum,

$$\|\mathbf{H}(\hat{w}_1, \dots, \hat{w}_{\tilde{N}}, \hat{b}_1, \dots, \hat{b}_{\tilde{N}})\hat{\beta} - \mathbf{T}\| \quad (4.7)$$

$$= \min_{w_i, b_i, \beta} \|\mathbf{H}(w_1, \dots, w_{\tilde{N}}, b_1, \dots, b_{\tilde{N}})\beta - \mathbf{T}\|$$

maliyet fonksiyonunu minimize etmeye eşdeğerdir

$$E = \sum_{j=1}^N \left(\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot w_j + b_i) - t_j \right)^2 \quad (4.8)$$

$\mathbf{H}$ bilinmediğinde, eğim düşüm tabanlı öğrenme algoritmaları genellikle $\|\mathbf{H}\beta - \mathbf{T}\|$ 'nin minimum değerini elde etmeye çalışır. Bu süreçte, ağırlık matrisi (w_i, β_i) ve bias (b_i) parametreleri ile vektör $\mathbf{W}$ tekrarlı olarak aşağıdaki gibi ayarlanır:

$$\mathbf{W}_k = \mathbf{W}_{k-1} - \eta \frac{\partial E(\mathbf{W})}{\partial \mathbf{W}} \quad (4.9)$$

Burada η bir öğrenme oranıdır. Geri-yayılımlı öğrenme algoritmalarının birçok sorunu bulunmaktadır. Bunlar,

- 1) η öğrenme oranı çok küçük olduğu zaman, öğrenme algoritması çok yavaş bir şekilde yakınsama yapar. Ancak, η çok büyük olduğunda, algoritma kararsız hale gelebilir ve yakınsama yapmayabilir.
- 2) Geri yayılım algoritmasının performansını etkileyen hata yüzeyinin bir başka özelliği de yerel minimumun olmasıdır [97]. Global bir minimumun çok üstünde bir yerde bulunması durumunda, öğrenme algoritmasının yerel bir minimumda durması istenmez.

- 3) Sinir ağı, geri yayılım algoritmaları kullanılarak aşırı eğitilmiş olabilir ve daha kötü genelleştirme performansı elde edilebilir. Bu nedenle, maliyet fonksiyonu minimize etme işlemleri sırasında doğrulama ve uygun durdurma yöntemleri gereklidir.
- 4) Eğitim düşüm tabanlı öğrenme algoritmalarında çoğu uygulamada çok zaman alır.

SLFN'lerin tüm parametrelerinin ayarlanması gerektiği konusundaki en yaygın anlayışın aksine, UÖM algoritmasında giriş ağırlıkları w_i ve gizli katman biasları b_i 'nin ayarlanmak zorunda olmayışı ve gizli katman çıkış matrisi $\mathbf{H}$ 'ın öğrenmenin başlangıcında bu parametrelere rasgele değerler atandığında değişmeden kalabilir.

Rastgele seçilen giriş ağırlıkları ile SLFN'lerin keyfi olarak küçük hatalarla farklı gözlemler öğrenebileceklerini göstermektedir [92]. Son zamanlarda, geleneksel fonksiyon yaklaşım teorilerinin aksine, giriş ağırlıkları ve gizli katman biasları rastgele atanmış ve sıfır olmayan aktivasyon fonksiyonlarına sahip ileri beslemeli sinir ağlarının herhangi bir giriş kümesini sürekli fonksiyonlara evrensel olarak yaklaşabileceği gösterilmiştir [87, 94].

Sunulan sonuçlar SLFN'lerin giriş ağırlıklarının ve gizli katman biaslarının ayarlanması gerekmediğini ve keyfi olarak verilebileceğini göstermektedir. Sabit giriş ağırlıkları ve gizli katman biasları için denk. (4.10)'da görüldüğü, Bir SLFN'yi eğitmek, $\mathbf{H}\beta = \mathbf{T}$ doğrusal sisteminin en küçük kareler çözümünü $\hat{\beta}$ 'yı bulmakla eşdeğerdir:

$$\begin{aligned} & \|H(w_1, \dots, w_N, b_1, \dots, b_N)\hat{\beta} - T\| \\ & = \min_{\beta} \|H(w_1, \dots, w_N, b_1, \dots, b_N)\beta - T\| \end{aligned} \quad (4.10)$$

Yukarıdaki doğrusal sistemin en küçük norm en küçük kareler çözümü:

$$\hat{\beta} = \mathbf{H}^+ \mathbf{T} \quad (4.11)$$

Ayrıca aşağıdaki önemli özellikler dikkate alındığında:

- 1) Minimum eğitim hatası. Özel çözüm $\hat{\beta} = \mathbf{H}^+ \mathbf{T}$, genel doğrusal bir sistemin $\mathbf{H}\beta = \mathbf{T}$ en küçük kareler çözümlerinden biridir, yani en küçük eğitim hatasına bu özel çözümle ulaşılabilir:

$$\|H\hat{\beta} - T\| = \|H\mathbf{H}^+ \mathbf{T} - T\| = \min_{\beta} \|H\beta - T\| \quad (4.12)$$

Neredeyse tüm öğrenme algoritmaları minimum eğitim hatasına ulaşmak istemesine rağmen, yerel minimum veya sınırlı eğitimde genellikle uygulamalarda yinelemeye izin verilmediği için minimum eğitim hatasına ulaşamaz.

- 2) En küçük ağırlık normu ve en iyi genelleme performansı. Ayrıca, özel çözüm $\hat{\beta} = \mathbf{H}^+ \mathbf{T}$, $\mathbf{H}\beta = \mathbf{T}$ 'nin tüm en küçük kareler çözümleri arasında en küçük norma sahip olanıdır:

$$\|\hat{\beta}\| = \|\mathbf{H}^+ \mathbf{T}\| \leq \|\beta\|, \quad (4.13)$$

$$\forall \beta \in \{\beta: \|\mathbf{H}\beta - \mathbf{T}\| \leq \|\mathbf{H}z - \mathbf{T}\|, \forall z \in \mathbb{R}^{\tilde{N} \times N}\}$$

Eğitim örneklerinde birçok küçük ağırlığa sahip ancak küçük kare hatası olan ileri besleme ağırları için Vapnik - Chervonenkis boyutu (ve dolayısıyla parametre sayısı) genelleme performansı ile ilgili değildir [43, 98]. Bunun yerine, ağırdaki ağırlıkların büyüklüğü daha önemlidir. Ağırlıklar ne kadar küçükse, ağırlık genelleme performansı daha iyi olur. UÖM algoritması kullanılarak hem eğitim örneklerinde en küçük karesel hataya ulaşılır hem de en küçük ağırlıklar elde edilir. Dolayısıyla, UÖM algoritması daha iyi genelleme performansına sahip olma eğilimindedir. Ağırlıkların büyüklüğünü dikkate almadan sadece en küçük eğitim hatasına ulaşmaya çalışan eğitim düşünüm tabanlı öğrenme algoritmalarının genelleme performansının kötüleşmesine neden olur.

- 3) Minimum norm en küçük kareler çözümü $\mathbf{H}\beta = \mathbf{T}$ benzersizdir ki bu durumda $\hat{\beta} = \mathbf{H}^+ \mathbf{T}$ 'dir.

Yukarıda bahsedilen nedenlerden dolayı, SLFN'ler için basit bir öğrenme algoritması olan UÖM'nin gerçekleştirilme adımları aşağıda verilmiştir.

UÖM Algoritması: Verilen bir eğitim seti $\mathbf{X} = \{(x_i, t_i) \mid x_i \in \mathbb{R}^n, t_i \in \mathbb{R}^m, i = 1, \dots, N\}$, aktivasyon fonksiyonu $g(x)$ ve gizli hücre sayısı $\tilde{N}$,

Adım 1: Gelişi güzel giriş ağırlığı w_i ve biaslar $b_i, i = 1, \dots, \tilde{N}$.

Adım 2: Gizli katman çıkış matrisi $\mathbf{H}$ 'ı hesapla.

Adım 3: Çıkış ağırlığını hesapla β :

$$\beta = \mathbf{H}^+ \mathbf{T} \quad (4.14)$$

$\mathbf{H}, \beta$ ve $\mathbf{T}$ denk. (7) ve (8) olarak tanımlanmıştır.

UÖM algoritmasının temel özellikleri aşağıda özetlenmiştir.


- 1) UÖM algoritmasının öğrenmesi son derece hızlıdır. SLFN'leri klasik öğrenme algoritmalarından çok daha hızlı sürede eğitebilir.
- 2) Minimum eğitim hatasına ulaşmak amacını güden ve ağırlıkların büyüklüğünü dikkate almayan geleneksel klasik eğitim düşünüm tabanlı öğrenme algoritmalarının aksine, UÖM algoritması yalnızca en küçük eğitim hatasına değil, aynı zamanda en küçük ağırlık normuna da ulaşma eğilimindedir. Bu nedenle, UÖM SLFN'ler için daha iyi genelleme performansına sahip olma eğilimindedir.
- 3) Yalnızca türevlenebilir aktivasyon fonksiyonları için kullanılabilen geleneksel eğitim düşünüm tabanlı öğrenme algoritmalarının aksine, UÖM algoritması, türevlenebilir olmayan aktivasyon fonksiyonları kullanılarak SLFN'lerin eğitiminde kullanılabilir.
- 4) Yerel minimum, uygun olmayan öğrenme oranı ve fazla bilgi, vb. gibi çeşitli olumsuz durumlarla karşılaşılacak geleneksel klasik eğitim düşünüm tabanlı öğrenme algoritmalarının aksine, UÖM doğrudan çözümlere ulaşma eğilimindedir.

Ayrıca birden fazla gizli katmana sahip ileri beslemeli sinir ağları için eğitim düşünüm tabanlı öğrenme algoritmalarının kullanılabileceği, mevcut şekilde UÖM algoritmasının sadece tek gizli katman ileri beslemeli ağları için geçerli olduğu belirtilmelidir. Ancak Ref. [99]'da yapılan çalışmada çok katmanlı sinir ağları için de UÖM algoritması gerçekleştirilmiştir.


5. DENEYSEL ÇALIŞMA

Bu bölümde, bir PV panelin çıkış gücünün UÖM algoritması kullanılarak elde edilen tahmin sonuçları verilmiştir. Bu amaçla 180 W'lık bir PV panel kurulmuştur. Ve bu panele ilişkin açık devre gerilimi, kısa devre akımı, güneş ışınlımı ve panel sıcaklığı deneysel olarak ölçülmüştür. PV panelin açık devre gerilimi ve kısa devre akımı kullanılarak panelin maksimum gücü hesaplanmıştır. UÖM'nin girişi panel sıcaklığı ve güneş ışınlımı, çıkışı ise panelin gücü seçilmiştir. Ayrıca UÖM'ye giriş ve çıkış değerleri normalize edilmiş ve sonuçlar 5-çapraz doğrulama kullanılarak verilmiştir. UÖM'nin performansını etkileyen en önemli parametreler gizli katman hücre sayısı ve bu katmandaki aktivasyon fonksiyonunun tipidir. Farklı gizli katman hücre sayısı değerleri ve farklı tip aktivasyon fonksiyonu için UÖM'nin regresyon eğitim sonuçları verilmiştir. UÖM'nin tahmin başarımını göstermek için UÖM'den elde edilen sonuçlar farklı regresyon modellerinde elde edilen sonuçlar ile karşılaştırılmıştır.

Tanjant sigmoid aktivasyon fonksiyonu kullanan UÖM için gizli katman hücre sayısı sırası ile 10 ve 20 kullanılarak elde edilen tahmin sonucu ile gerçek sonuçlar Şekil 5.1'de, regresyon eğrisine ilişkin sonuç ise Şekil 5.2'de verilmiştir. Şekil 5.1(a) ve (b) incelendiği zaman, hücre sayısı arttıkça UÖM'nin tahmin başarımının arttığı görülmektedir. Bu durum regresyon eğrilerinden de görülmektedir. Gizli katman hücre sayısı 10'dan 20'ye arttırıldığında R değeri 0.99998'den 1 değerine yükselmektedir.




(a) Gizli katman hücre sayısı 10 için




(b) Gizli katman hücre sayısı 20 için

Şekil 5.1. Gerçek güç değerleri ve tanjant sigmoid aktivasyon fonksiyonu kullanan UÖM'nin tahmin ettiği güç değerleri




(a) Gizli katman hücre sayısı 10 için




(b) Gizli katman hücre sayısı 20 için

Şekil 5.2. Tanjant sigmoid aktivasyon fonksiyonu kullanan UÖM'nin gizli katman hücre sayısı 10 ve 20 için regresyon eğrileri

Radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin tahmin sonuçları gizli katman hücre sayısı sırası ile 10 ve 20 için Şekil 5.3'te, regresyon eğrisine ilişkin sonuçlar Şekil 5.4'te verilmiştir. Şekil 5.3 ve 5.4 incelendiği zaman, tanjant aktivasyon fonksiyonu kullanan UÖM'de olduğu gibi radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin tahmin başarımının hücre sayısı arttıkça iyileştiği ve R değerinin 0.99973'ten 1 değerine arttığı görülmektedir.




(a) Gizli katman hücre sayısı 10 için




(b) Gizli katman hücre sayısı 20 için

Şekil 5.3. Gerçek güç değerleri ve radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin tahmin ettiği güç değerleri



(a) Gizli katman hücre sayısı 10 için




(b) Gizli katman hücre sayısı 20 için


Şekil 5.4. Radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin gizli katman hücre sayısı 10 ve 20 için regresyon eğrileri

Üçgen aktivasyon fonksiyonu kullanan UÖM'nin tahmin sonuçları gizli katman hücre sayısı sırası ile 10 ve 20 için Şekil 5.5'te, regresyon eğrisine ilişkin sonuçlar Şekil 5.6'da

verilmiştir. Bu şekiller incelendiği zaman, üçgen aktivasyon fonksiyonu kullanan UÖM'nin tahmin başarımının diğer aktivasyon fonksiyonları kullanan UÖM'de olduğu gibi hücre sayısı arttıkça iyileştiği ve R değerinin 0.99948'den 0.99981'e artmaktadır. Ancak tanjant sigmoid ve radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin tahmin başarımının üçgen aktivasyon fonksiyonu kullanan UÖM'den daha iyi olduğu elde edilen sonuçlardan görülmektedir.




(a) Gizli katman hücre sayısı 10 için




(b) Gizli katman hücre sayısı 20 için

Şekil 5.5. Gerçek güç değerleri ve radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin tahmin ettiği güç değerleri



(a) Gizli katman hücre sayısı 10 için



(b) Gizli katman hücre sayısı 20 için

Şekil 5.6. Üçgen aktivasyon fonksiyonu kullanan UÖM'nin gizli katman hücre sayısı 10 ve 20 için regresyon eğrileri


Gizli katman hücre sayısının (GKHS) farklı değerleri ve farklı aktivasyon tipleri için UÖM'den elde edilen kök kare ortalama hata (RMSE) ve eğitim süreleri Tablo 5.1'de

verilmiştir. Bu tablodan en düşük RMSE değerinin GKSH'nin 20 değeri ve radyal tabanlı aktivasyon fonksiyonu için elde edildiği görülmektedir. Ayrıca GKHS arttıkça eğitim süresi de artmaktadır.


Tablo 5.1. Gizli katman hücre sayısının (GKHS) farklı değerleri ve farklı aktivasyon tipleri için UÖM'den elde edilen RMSE ve eğitim süreleri

Aktivasyon tipi	GKHS	RMSE	Eğitim süresi
Tanjant sigmoid	10	3.9646×10^{-4}	0.0136
	20	4.5486×10^{-5}	0.0156
Radyal tabanlı	10	5.2283×10^{-4}	0.0156
	20	4.8058×10^{-5}	0.0156
Üçgen	10	7.4147×10^{-4}	0.0156
	20	0.0011	0.0313


UÖM'nin tahmin başarımındaki etkinliğini göstermek için tahmin sonuçları ayrıca lineer regresyon modeli (LRM), dayanıklı lineer regresyon modeli (DLRM), doğrusal destek vektör makineleri (DDVM), kuadratik destek vektör makineleri (KDVM), üstel Gauss regresyon modeli (ÜGRM) ve rasyonel kuadratik Gauss regresyon modeli (RKGRM) ile de elde edilmiştir. Bu modellerden elde edilen sonuçlar Şekil 5.7'de, performans parametreleri (RMSE, ortalama karesel hata (MSE), ortalama mutlak hata (MAE)) ise Tablo 5.2'de verilmiştir. Elde edilen sonuçlar incelendiği zaman, regresyon modelleri içinde DLRM ve RKGRM'nin PV panelin çıkış gücünü yüksek bir başarımla tahmin ettiği görülmektedir.




(a) Lineer regresyon modeli




(b) Dayanıklı lineer regresyon modeli




(c) Doğrusal destek vektör makineleri



(d) Kuadratik destek vektör makineleri



(e) Üstel Gauss regresyon modeli



(f) Rasyonel kuadratik Gauss regresyon modeli

Şekil 5.7. Farklı regresyon modellerinden elde edilen tahmin sonuçları

Tablo 5.2. Regresyon modelleri için performans parametreleri

Model	RMSE	MSE	MAE	R^2	Eğitim süresi
LRM	0.91443	0.83618	0.52695	1	14.642
DLRM	0.0020778	4.3172e-6	0.00061311	1	12.488
DDVM	2.5784	6.6481	2.0225	0.99	33.335
KDVM	3.4924	12.197	2.8063	0.99	33.117
ÜGRM	3.0472	9.2857	1.3957	.99	64.147
RKGRM	0.079101	0.0062569	0.051105	1	63.537

Elde edilen sonuçlar incelendiği zaman UÖM, DLRM ve RKGRM'nin PV panelin çıkış gücünü yüksek bir başarımla tahmin ettiği görülmektedir. Bunun yanında, bu üç model arasında yapısının diğer modellere göre daha basit ve eğitim süresinin daha kısa olması nedeni ile UÖM'nin diğer iki modele göre daha üstün olduğu söylenebilir. Bu sonuçlardan, UÖM'nin PV sistemlerin çıkış gücünün tahmininde bir araç olarak kullanılabileceği görülmüştür.

6. SONUÇLAR

Dünya nüfusunun artması ve gelişen teknolojiye paralel olarak insanoğlunun enerjiye olan ihtiyacı sürekli artmaktadır. Artan bu ihtiyacı karşılamak için en yaygın fosil yakıtlar kullanılmaktadır. Fosil yakıtlar ise hem hızla tükenmekte hem de küresel ısınmaya neden olmaktadır. Bu nedenlerden dolayı, çevre sorunlarına sebep olmayan, temiz, güvenilir ve sürdürülebilir yenilenebilir enerji kaynakları, insanoğlunun geleceği için büyük önem taşımaktadır. Bu enerji üretimleri, birincil enerjilerin temini için diğer ülkelere olan bağımlılığın da ortadan kaldırılmasında önemli bir rol oynamaktadır. PV tabanlı elektrik üretiminin artması, geleneksel fosil yakıt tabanlı teknolojilere kıyasla çevre için avantajlar sağlamaktadır. Ancak, bulutlar ve hava koşulları güneş enerjisinin kullanılabilirliğini etkileyebilir. Bu nedenle güneş enerjisinden üretilen elektrik enerjisi farklı parametrelere bağlı olarak değişken olabilir. Bu nedenlerden dolayı güneş santralleri ile yük talebine cevap vermek çok zor bir görevdir. Bu durumu önlemenin bir yolu PV sistemlerin çıkış gücünü tahmin etmektir.

Bu çalışmada 180 W'lık panel kurularak, UÖM'nin giriş ve çıkış parametreleri; panel sıcaklığı, güneş ışınımı, panelin açık devre gerilimi ve kısa devre akımı 15 dk.lık aralıklarla ölçülmüştür. Panelin güç değerleri hesaplanırken açık devre gerilimi ve kısa devre akımından faydalanılmıştır. Çalışma sonucunda 75 adet deneysel veri elde edilmiştir. UÖA başarımlarını iyileştirmek için UÖM'nin bazı parametreleri (giriş nöron sayısı, aktivasyon fonksiyonu) deneme yanılma yöntemi ile en iyi sonucu verecek şekilde ayarlanmıştır. Oluşturulan veri kümesi eğitim ve test kümeleri olarak ayrılmıştır. Yöntemin başarımlarını 5-katlamalı çapraz doğrulama yöntemi ile incelenmiştir. Bu amaçla, veri kümesi 5 eşit parçaya bölünmüştür. Bu parçalardan biri test için ayrılıp geri kalan dördü ağın eğitimi için kullanılır ve bu işlem her defasında test kümesi değiştirilerek gerçekleştirilir. Toplamda 5 defa ağ farklı kümelerle eğitilip test edilmiş olur. Ağın test sonucunda, bütün test fonksiyonlarının performanslarının toplamının ortalaması alınır. UÖA algoritması MATLAB yazılımı kullanılarak gerçekleştirilmiştir. Ayrıca PV panelin çıkış gücünün tahmini için farklı regresyon modelleri de kullanılmış ve bu modellerden elde edilen sonuçlar UÖM'nin sonuçları ile karşılaştırılmıştır. Elde edilen regresyon sonuçlarından, UÖM'nin PV panelin çıkış gücünü çok yüksek doğrulukta tahmin ettiği görülmüştür. Ayrıca UÖM'nin eğitim süresinin diğer regresyon modellerine göre daha kısa ve eğitim

algoritmasının çok basit olması gibi üstünlükleri UÖM'yi PV panellerin çıkış gücünün tahmininde etkin bir araç olarak kullanılabileceğini göstermiştir.



KAYNAKLAR

- [1] **Canka Kılıç,F.** (2015). GÜNEŞ ENERJİSİ, TÜRKİYE’DEKİ SON DURUMU VE ÜRETİM TEKNOLOJİLERİ. *Engineer & The Machinery Magazine*, (671).
- [2] **Dünya Enerji Konseyi Türk Milli Komitesi.** 2009. Dünya’da ve Türkiye’de Güneş Enerjisi, ISBN: 978-605-89548-2-3. DEKTMK YAYIN NO: 0011/2009, EKC Form Ofset, Ankara.
- [3] **Alanazi, M. S.** (2014). Solar power deployment: Forecasting and planning.
- [4] “Global Market Outlook For Photovoltaics,” *European Photovoltaic Industry Association (EPIA)*, 2013. [Online]. Available: <http://www.epia.org/news/publications/global-market-outlook-for-photovoltaics-2014-2018/>.
- [5] “Solar Market Insight Report 2013 Year in Review | SEIA.” [Online]. Available: <http://www.seia.org/research-resources/solar-market-insight-report-2013-yearreview>. [Accessed: 02-Sep-2014].
- [6] **IRENA**, “Renewable Energy Technologies: Cost Analysis Series.” Jun-2012.
- [7] “Feed-in tariff: A policy tool encouraging deployment of renewable electricity technologies - Today in Energy - U.S. Energy Information Administration (EIA).” [Online]. Available: <http://www.eia.gov/todayinenergy/detail.cfm?id=11471>. [Accessed: 03-Sep-2014].
- [8] “Solar Photovoltaics-Technology Brief.” IEA-ETSAP and IRENA, Jan-2013.
- [9] “NREL: Transmission Grid Integration - Variability of Renewable Energy Sources.” [Online]. Available: <http://www.nrel.gov/electricity/transmission/variability.html>. [Accessed: 04-Sep-2014].
- [10] **E. Ela, V. Diakov, E. Ibanez, and M. Heaney**, “Impacts of variability and uncertainty in solar photovoltaic generation at multiple timescales,” *Contract*, vol.303, pp. 275–3000, 2013.
- [11] “Systems Integration | Department of Energy.” [Online]. Available: <http://energy.gov/eere/sunshot/systems-integration>. [Accessed: 04-Sep-2014].
- [12] **A. S. Anees**, “Grid Integration of Renewable Energy Sources: Challenges, Issues and Possible Solutions,” in *Power Electronics (IICPE), 2012 IEEE 5th India International Conference on*, 2012, pp. 1–6.
- [13] **C. Monteiro, T. Santos, L. Fernandez-Jimenez, I. Ramirez-Rosado, and M. Terreros-Olarte**, “Short-Term Power Forecasting Model for Photovoltaic

Plants Based on Historical Similarity,” *Energies*, vol. 6, no. 5, pp. 2624–2643, May 2013.

- [14] **V. P. Singh, K. Vaibhav, and D. K. Chaturvedi**, “Solar power forecasting modeling using soft computing approach,” in *Engineering (NUiCONE), 2012 Nirma University International Conference on*, 2012, pp. 1–5.
- [15] “The importance of wind forecasting - Renewable Energy Focus.” [Online]. Available: <http://www.renewableenergyfocus.com/view/1379/the-importance-ofwind-forecasting/>. [Accessed: 05-Sep-2014].
- [16] **H. M. Diagne, M. David, P. Lauret, and J. Boland**, “Solar irradiation forecasting: state-of-the-art and proposition for future developments for small-scale insular grids,” American Solar Energy Society, 2012.
- [17] **A. Brown, S. muller, and Z. Dobrotkova**, “Renewable energy markets and prospects by technology,” Tech. Rep., 2011 November.
- [18] “Technology roadmap. solar photovoltaic energy,” International Energy Agency, Tech.Rep., 2010.
- [19] NREL. National renewable energy laboratory. [Online]. Available: <http://www.nrel.gov/ncpv/>.
- [20] **J. Tian, Y. qiang Zhu, and J. neng Tang**, “Photovoltaic array power forecasting model based on energy storage,” in *Critical Infrastructure (CRIS), 2010 5th International Conference on*, Sep 2010, pp. 1–4.
- [21] **Y. T. Tan and D. S. Kirschen**, “Impact on the power system of a large penetration of photovoltaic generation,” in *Proceedings of the IEEE Power Engineering Society General Meeting*, pp. 1–8, June 2007.
- [22] **E. Skoplaki and J. A. Palyvos**, “On the temperature dependence of photovoltaic module electrical performance: a review of efficiency/power correlations,” *Solar Energy*, vol. 83, no. 5, pp. 614–624, 2009.
- [23] **E. Lorenz, J. Hurka, D. Heinemann, and H. Beyer**, “Irradiance forecasting for the power prediction of grid-connected photovoltaic systems,” *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, vol. 2, no. 1, pp. 2–10, March 2009.
- [24] **V. Lara-Fanego, J. Ruiz-Arias, D. Pozo-Vazquez, F. Santos-Alamillos, and J. Tovar-Pescador**, “Evaluation of the WRF model solar irradiance forecasts in Andalusia (south-ern Spain),” *Solar Energy*, vol. 86, no. 8, pp. 2200–2217, 2012, progress in Solar Energy3.
- [25] **S. Pelland, G. Galanis, and G. Kallos**, “Solar and photovoltaic forecasting through post-processing of the global environmental multiscale numerical weather prediction model,” *Progress in Photovoltaics: Research and Applications*,

vol. 21, no. 3, pp.284–296, 2013. [Online]. Available: <http://dx.doi.org/10.1002/pip.1180>.

- [26] **R. Perez, K. Moore, S. Wilcox, D. Renn, and A. Zelenka**, “Forecasting solar radiation-preliminary evaluation of an approach based upon the national forecastdatabase,” *Solar Energy*, vol. 81, no. 6, pp. 809 – 812, 2007. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0038092X06002404>.
- [27] **A. Hammer, D. Heinemann, E. Lorenz, and B. Lucke**, “Short-term forecasting of solar radiation: a statistical approach using satellite data,” *Solar Energy*, vol. 67, pp. 139 – 150, 1999.
- [28] **R. Perez, S. Kivalov, J. Schlemmer, K. H. Jr., D. Renn, and T. E. Hoff**, “Validation of short and medium term operational solar radiation forecasts in theUS,” *Solar Energy*, vol. 84, no. 12, pp. 2161 – 2172, 2010. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0038092X10002823>.
- [29] **A. Mellit and S. A. Kalogirou**, “Artificial intelligence techniques for photovoltaic applications: A review,” *Progress in Energy and Combustion Science*, vol. 34, no. 5, pp. 574 – 632, 2008. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0360128508000026>.
- [30] **Elizondo, D., Hoogenboom, G., & McClendon, R. W.** (1994). Development of a neural network model to predict daily solar radiation. *Agricultural and Forest Meteorology*, 71(1-2), 115-132.
- [31] **Mohandes, M., Rehman, S., & Halawani, T. O.** (1998). Estimation of global solar radiation using artificial neural networks. *Renewable energy*, 14(1-4), 179-184.
- [32] **Şen, Z.** (1998). Fuzzy algorithm for estimation of solar irradiation from sunshine duration. *Solar Energy*, 63(1), 39-49. Şen, Z. (1998). Fuzzy algorithm for estimation of solar irradiation from sunshine duration. *Solar Energy*, 63(1), 39-49.
- [33] **Al-Alawi, S. M., & Al-Hinai, H. A.** (1998). An ANN-based approach for predicting global radiation in locations with no direct measurement instrumentation. *Renewable Energy*, 14(1-4), 199-204.
- [34] **Mellit, A., Benghanem, M., Arab, A. H., & Guessoum, A.** (2005). A simplified model for generating sequences of global solar radiation data for isolated sites: Using artificial neural network and a library of Markov transition matrices approach. *Solar Energy*, 79(5), 469-482.
- [35] **Alzahrani, A., Shamsi, P., Dagli, C., & Ferdowsi, M.** (2017). Solar irradiance forecasting using deep neural networks. *Procedia Computer Science*, 114, 304-313.

- [36] **B. Zhao, X. Ge, M. Xue, X. Zhang, and W. Xu**, “Research on model for photovoltaic system power forecasting,” in *Electricity Distribution (CICED), 2010 China International Conference on*, sept. 2010, pp. 1 –5.
- [37] **Y. Huang, J. Lu, C. Liu, X. Xu, W. Wang, and X. Zhou**, “Comparative study of power forecasting methods for PV stations,” in *Power System Technology (POWERCON), 2010 International Conference on*, oct. 2010, pp. 1 –6.
- [38] **D. Caputo, F. Grimaccia, M. Mussetta, and R. Zich**, “Photovoltaic plants predictive model by means of ANN trained by a hybrid evolutionary algorithm,” in *Neural Networks (IJCNN), The 2010 International Joint Conference on*, july 2010, pp. 1 –6.
- [39] **F. Grimaccia, M. Mussetta, and R. Zich**, “Neuro-fuzzy predictive model for pv energy production based on weather forecast,” in *Fuzzy Systems (FUZZ), 2011 IEEE International Conference on*, june 2011, pp. 2454 –2457.
- [40] **J. Shi, W.-J. Lee, Y. Liu, Y. Yang, and P. Wang**, “Forecasting power output of photovoltaic systems based on weather classification and support vector machines,” *Industry Applications, IEEE Transactions on*, vol. 48, no. 3, pp. 1064 –1069, May-Jun 2012.
- [41] **R. Xu, H. Chen, and X. Sun**, “Short-term photovoltaic power forecasting with weighted support vector machine,” in *Automation and Logistics (ICAL), 2012 IEEE International Conference on*, 2012, pp. 248–253.
- [42] **O’Leary, D., & Kubby, J.** (2017). Feature Selection and ANN Solar Power Prediction. *Journal of Renewable Energy*, 2017.
- [43] **Huang, G.-B., Zhu, Q.-Y. and Siew, C.-K.**, 2006. Extreme learning machine: theory and applications, *Neurocomputing*, 70(1), 489–501.
- [44] **Ranabhat, Kiran, et al.** "An introduction to solar cell technology." *Journal of Applied Engineering Science* 14.4 (2016): 481-491.
- [45] **Özçelik S.**, Fotovoltaik (PV) Teknolojileri. file:///C:/Users/toshiba/Downloads/fotovoltaik-teknolojileri%20(2).pdf (10.08.2018).
- [46] **Singh, S., Mathew, L., & Shimi, S. L.** (2013). Design and simulation of intelligent control MPPT technique for PV module using MATLAB/SIMSCAPE. *Int. J. Adv. Res. Electr. Electron. Instrum. Eng*, 2, 4554-4566.
- [47] **Özdemir Ş.**, 2007. Fotovoltaik Sistemler için Mikrodenetleyicili En Yüksek Güç Noktasını İzleyen Bir Konvertörün Gerçekleştirilmesi, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

- [48] **Morales, D. S.**,2010. Maximum Power Point Tracking Algorithms for Photovoltaic Applications, Thesis submitted for examination for the degree of Master of Science in Technology, Aalto University.
- [49] **A. Goetzberger and V. U. Hoffmann**,*Photovoltaic solar energy generation*. Springer,2005, vol. 112.
- [50] **H.-L. Tsai, C.-S. Tu, and Y.-J. Su**, “Development of generalized photovoltaic model using matlab/simulink,” in *Proceedings of the World Congress on Engineering and Computer Science*, 2008, pp. 846–851.
- [51] **T.Markvart and L. Castaner**,*Solar cells: materials, manufacture and operation*. AccessOnline via Elsevier, 2004.
- [52] **Öztürk, H. H.** Güneş Enerjisinden Fotovoltaik Yöntemle Elektrik Üretiminde Güç Dönüşüm Verimi ve Etkili Etmenler.
- [53] **Salas, V., Olias, E., Barrado, A., & Lazaro, A.** (2006). Review of the maximum power point tracking algorithms for stand-alone photovoltaic systems. *Solar energy materials and solar cells*, 90(11), 1555-1578.
- [54] **Esrām, T.,& Chapman, P. L.** (2007). Comparison of photovoltaic array maximum power point tracking techniques. *IEEE Transactions on energy conversion*, 22(2), 439-449.
- [55] **Kumari, J. S.,& Babu, C. S.** (2011). Comparison of maximum power point tracking algorithms for photovoltaic system. *International Journal of Advances in Engineering & Technology*, 1(5), 133.
- [56] **Elgharbaoui, E., Essadki, A., & Nasser, T.** (2014, November). MPPT commands for a photovoltaic generator using the Incremental Conductance Method and the fuzzy logic command. In *2014 International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM)* (pp. 1-6). IEEE.
- [57] **Brano, V. L.,& Ciulla, G.** (2013). An efficient analytical approach for obtaining a five parameters model of photovoltaic modules using only reference data. *Applied Energy*, 111, 894-903.
- [58] **M. Veerachary, T. Senjyu, and K. Uezato**, “Neural-networkbased maximum-power-point tracking of coupled-inductor interleaved-boost-converter-supplied PV system using fuzzy controller,” *IEEE Transactions on Industrial Electronics*, vol. 50, no. 4, pp. 749–758, 2003.
- [59] **V. Lo Brano, G. Ciulla, and M. Beccali**, “Application of adaptive models for the determination of the thermal behaviour of a photovoltaic panel,” in *Proceedings of the International Conferences on Computational Science and Its Applications (ICCSA '13)*, pp. 344–358, Springer, Ho Chi Minh City, Vietnam, 2013.

- [60] **Satpathy, S.** (2012). *Photovoltaic power control using MPPT and boost converter* (Doctoral dissertation).
- [61] **Aashoor F. A. O.,** 2015. Maximum power point tracking techniques for photovoltaic water pumping system, A thesis submitted for the degree of Doctor of Philosophy, Department of Electronic and Electrical Engineering University of Bath (in England)
- [62] **Ardağ Y.,**2012. Güneş Pili Karakteristiklerinin İncelenmesi, Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli.
- [63] **Yakışan Ö.,** 2008. Güneş enerjisi üretim sistemlerinde bir Maksimum güç noktası izleme yöntemi ile bir şebeke bağlantılı eviricinin geliştirilmesi ve gerçekleştirilmesi, Doktora Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- [64] **Tafticht, T., Agbossou, K., Doumbia, M. L., & Cheriti, A.** (2008). An improved maximum power point tracking method for photovoltaic systems. *Renewable energy*, 33(7), 1508-1516.
- [65] **Saidi, A. & Benachaiba, C.,**2016. Comparison of IC and P&O Algorithms in MPPT for Grid Connected PV module, 8th International Conference on Modelling, Identification and Control (ICMIC),IEEE, Algiers, Algeria, 15-17 November, pp. 213-218.
- [66] **M. Santarelli and S. Macagno,** “A thermoeconomic analysis of a PV-hydrogen system feeding the energy requests of a residential building in an isolated valley of the alps,” *Energy Conversion and Management*, vol. 45, no. 3, pp. 427 – 451, 2004. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0196890403001560>.
- [67] **Enphase Energy.** [Online]. Available: <https://enlighten.enphaseenergy.com/pv/publicSystems>.
- [68] **Varınca, K. B.,& Gönüllü, M. T.** (2006). Türkiye’de güneş enerjisi potansiyeli ve bu potansiyelin kullanım derecesi, yöntemi ve yaygınlığı üzerine bir araştırma. *I. Ulusal Güneş ve Hidrojen Enerjisi Kongresi*, (s 272), 275.
- [69] **Masoum, M. A., Dehbonei, H. & Fuchs, E. F.,** 2002. Theoretical and Experimental Analyses of Photovoltaic Systems with Voltage and Current-Based Maximum Power-Point Tracking. *IEEE Transactions on Energy Conversion*, 17(4), pp.514-522.
- [70] **Hu, J., Zhang, J. & Wu, H.,** 2009. A Novel MPPT Control Algorithm Based on Numerical Calculation for PV Generation Systems, 2009 IEEE 6th International Power Electronics and Motion Control Conference, IEEE, Wuhan, China ,17-20 May 2009 , pp. 2103-2107.

- [71] **Soufi, Y., Bechouat, M. & Kahla, S.,** 2017. Fuzzy-PSO Controller Design for Maximum Power Point Tracking in Photovoltaic System, *International Journal of Hydrogen Energy*, 42(13), pp.8680-8688.
- [72] **Femia, N., Petrone, G., Spagnuolo, G. & Vitelli, M.,** 2005. Optimization of Perturb and Observe Maximum Power Point Tracking Method, *IEEE Transactions on Power Electronics*, 20 (4), pp.963-973.
- [73] **Al-Diab, A. & Sourkounis, C.,**2010. Variable Step Size P&O MPPT Algorithm for PV Systems, 12th International Conference on Optimization of Electrical and Electronic Equipment, IEEE, Basov, Romania, 20-22 May, pp. 1097-1102.
- [74] **Uddin, M. H., Baig, M. A. & Ali, M.,** 2016. Comparison of Perturb & Observe and Incremental Conductance, Maximum Power Point Tracking Algorithms on Real Environmental Conditions'', International Conference on Computing, Electronic and Electrical Engineering (ICE Cube), IEEE, Quetta, Pakistan, 11-12 April, pp. 313-317.
- [75] **Eltawil, M. A. & Zhao, Z.,**2013. MPPT Techniques for Photovoltaic Applications, *Renewable and Sustainable Energy Reviews*, 25, pp.793-813.
- [76] **Ikegami, T., Maezono, T., Nakanishi, F., Yamagata, Y., & Ebihara, K.** (2001). Estimation of equivalent circuit parameters of PV module and its application to optimal operation of PV system. *Solar energy materials and solar cells*, 67(1-4), 389-395.
- [77] **Santos, J. & Antunes, F.,** 2003. Maximum Power Point Tracker for PV Systems. World Climate and Energy Event, Rio de Janeiro, Brazil, pp. 75-80, 1-5 December.
- [78] **Berrera, M. , Dolara, A. , Faranda, R. & Leva, S.,** 2009. Experimental Test of Seven Widely-Adopted MPPT Algorithms, *IEEE Bucharest Power Tech Conference*, Bucharest, Romania, 28 June-2 July, pp:1-8.
- [79] **Baek, J. W., Ko, J. S., Choi, J. S., Kang, S. J. & Chung, D. H.,** 2010. Development of Novel MPPT Algorithm of PV System Considering Radiation Variation, *International Conference on Control, Automation and Systems*, IEEE, Gyeonggi-do, South Korea, 27-30 October, pp.1235-1241.
- [80] **Revankar, P. S., A. G. Thosar, and W. Z. Gandhare.** "Maximum power point tracking for PV systems using MATLAB/SIMULINK." 2010 Second International Conference on Machine Learning and Computing. IEEE, 2010
- [81] **Veerachary, Mummadi.** "Power tracking for nonlinear PV sources with coupled inductor SEPIC converter." *IEEE transactions on aerospace and electronic systems* 41.3 (2005): 1019-1029.
- [82] **Ramos-Hernanz, J. A., et al.** "Study of the behavior of the incremental conductance algorithm for MPPT." 2016 8th International Conference on Electronics, Computers and Artificial Intelligence (ECAI). IEEE, 2016.

- [83] **Vipin, P., Beena, V. & Jarayaju, M.,** (2012). Fuzzy Logic Based Maximum Power Point Tracker for a Photovoltaic System, International Conference on Power, Signals, Controls and Computation (EPSCICON),IEEE, Kerala, India,3-6 January, pp. 1-6.
- [84] **Ali, U. S. (2016).** Z-source DC-DC Converter with Fuzzy Logic MPPT Control for Photovoltaic Applications. *Energy Procedia*, 90, 163-170.
- [85] **Pedrycz, Witold, and Fernando Gomide.** An introduction to fuzzy sets: analysis and design. Mit Press, 1998.
- [86] **Calcev, George.** "Some remarks on the stability of Mamdani fuzzy control systems." IEEE Transactions on Fuzzy Systems 6.3 (1998): 436-442.
- [87] **K. Hornik,** "Approximation capabilities of multilayer feedforward networks," Neural Networks, vol. 4, pp. 251—257, 1991.
- [88] **M. Leshno, V. Y. Lin, A. Pinkus, and S. Schocken,** "Multilayer feedforward networks with a nonpolynomial activation function can approximate any function," Neural Networks, vol. 6, pp. 861—867, 1993.
- [89] **Y. Ito,** "Approximation of continuous functions on R^d by linear combinations of shifted rotations of a sigmoid function with and without scaling," Neural Networks, vol. 5, pp. 105—115, 1992.
- [90] **G.-B. Huang and H. A. Babri,** "Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions," IEEE Transactions on Neural Networks, vol. 9, no. 1, pp. 224—229, 1998.
- [91] **S. Tamura and M. Tateishi,** "Capabilities of a four-layered feedforward neural network: Four layers versus three," IEEE Transactions on Neural Networks, vol. 8, no. 2, pp. 251—255, 1997.
- [92] **G.-B. Huang,** "Learning capability and storage capacity of two-hidden-layer feedforward networks," IEEE Transactions on Neural Networks, vol. 14, no. 2, pp. 274—281, 2003.
- [93] **G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew,** "Real-time learning capability of neural networks," in Technical Report ICIS/45/2003, (School of Electrical and Electronic Engineering, Nanyang Technological University, Singapore), Apr. 2003.
- [94] **G.-B. Huang, L. Chen, and C.-K. Siew,** "Universal approximation using incremental feedforward networks with arbitrary input weights," in Technical Report ICIS/46/2003, (School of Electrical and Electronic Engineering, Nanyang Technological University, Singapore), Oct. 2003.

- [95] **P. L. Bartlett**, “The sample complexity of pattern classification with neural networks: The size of the weights is more important than the size of the network,” *IEEE Transactions on Information Theory*, vol. 44, no. 2, pp. 525—536, 1998.
- [96] **D. Serre**, “Matrices: Theory and applications,” Springer-Verlag New York, Inc, 2002.
- [97] **S. Haykin**, “Neural networks: A comprehensive foundation,” New Jersey: Prentice Hall, 1999.
- [98] **P. L. Bartlett**, “For valid generalization, the size of the weights is more important than the size of the network,” in *Advances in Neural Information Processing Systems’ 1996* (M. Mozer, M. Jordan, and T. Petsche, eds.), vol. 9, pp. 134—140, MIT Press, 1997.
- [99] **Tang, Jiexiong, Chenwei Deng, and Guang-Bin Huang**. "Extreme learning machine for multilayer perceptron." *IEEE transactions on neural networks and learning systems* 27.4 (2015): 809-821.

ÖZGEÇMİŞ

1978 yılında Elazığ'da doğdu. İlk, orta ve lise öğrenimini Elazığ'da tamamladı. 1999 yılında Fırat Üniversitesi Elektronik-Bilgisayar Eğitimi Bölümü Bilgisayar Öğretmenliği Bölümünden mezun oldu. 1999 yılında Gaziantep ilinde Bilgisayar Öğretmeni olarak göreve başladı. 2001 yılı eylül ayından beri Elazığ'da öğretmen olarak çalışmaktadır. Evli ve iki çocuk babasıdır.

