



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



**DAĞITILMIŞ GÜÇ ÜRETİMİ İÇİN SOLAR**  
**FOTOVOLTAİK SİSTEMİN YAPAY ZEKA**  
**TABANLI HİBRİT KONTROLÜ**

**Umair YOUNAS**

**DOKTORA TEZİ**

**Elektrik - Elektronik Mühendisliği Anabilim Dalı**

**Şubat - 2024**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Umair YOUNAS tarafından hazırlanan “DAĞITILMIŞ GÜÇ ÜRETİMİ İÇİN SOLAR FOTOVOLTAİK SİSTEMİN YAPAY ZEKÂ TABANLI HİBRİT KONTROLÜ” adlı tez çalışması 12/02/2024 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektrik – Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. Ömer AYDOĞDU  
(Konya Teknik Üniversitesi)

.....

#### Danışman

Prof. Dr. Ahmet Afşin KULAKSIZ  
(Konya Teknik Üniversitesi)

.....

#### Üye

Prof. Dr. Bahadır AKBAL  
(Aksaray Üniversitesi)

.....

#### Üye

Doç. Dr. Hulusi KARACA  
(Selçuk Üniversitesi)

.....

#### Üye

Doç. Dr. Mümtaz MUTLUER  
(Necmettin Erbakan Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Ömer Faruk YÜKSEL  
Enstitü Müdürü

Bu tez çalışması Yurtdışı Türkler ve Akraba Topluluklar Başkanlığı tarafından 17PK006897 nolu proje ile desteklenmiştir.

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Umair YOUNAS

İmza: \_\_\_\_\_

Tarih: 12 - 02 - 2024

## ÖZET

### DOKTORA TEZİ

## DAĞITILMIŞ GÜÇ ÜRETİMİ İÇİN SOLAR FOTOVOLTAİK SİSTEMİN YAPAY ZEKA TABANLI HİBRİT KONTROLÜ

Umair YOUNAS

Selçuk Üniversitesi Fen Bilimleri Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ahmet Afşin KULAKSIZ

2024, 178 Sayfa

Jüri

Prof. Dr. Ahmet Afşin KULAKSIZ

Prof. Dr. Ömer AYDOĞDU

Prof. Dr. Bahadır AKBAL

Doç. Dr. Hulusi KARACA

Doç. Dr. Mümtaz MUTLUER

Kentleşme ve nüfus artışı nedeniyle artan enerji talebi ve sera gazı emisyonlarını azaltma ihtiyacı, enerji piyasalarını güneş fotovoltaikleri (PV) gibi yenilenebilir enerji kaynaklarına yönlendirmektedir. Bununla birlikte, güneş paneli verimliliği sınırlıdır (%15-25) ve çıkış gücü sıcaklık (T) ve ışıyım (G) değişiklikleriyle dalgalanarak şebekeye bağlı PV uygulamalarını kısıtlar. Bu zorlukların üstesinden gelmek için bu tez, şebekeye bağlı 100 kW'lık bir PV sistemi için maksimum güç noktası izleme (MPPT) kontrolü olarak denetimli bir derin öğrenme uzun kısa süreli bellek (LSTM) ağı sunmaktadır. LSTM tabanlı MPPT, Simulink MATLAB2023© kullanılarak ileri beslemeli derin sinir ağı (FF-DNN) ve geleneksel değiştir ve gözle (P&O) MPPT ile karşılaştırılmıştır. DL tabanlı MPPT kontrolörlerinin performansı ortalama kare hata, kök ortalama kare hata, ortalama ortalama hata, R2 skoru ve güç tahmin hatası ile değerlendirilmiştir. Başlangıçta, bir milyon veri noktası toplanmış, ön işleme tabi tutulmuş (z-skor normalizasyonu) ve eğitim ve test setlerine 80/20 oranında bölünmeden önce görselleştirilmiştir (çubuk grafikler, histogram ve korelasyon matrisi). LSTM ve FF-DNN, Adam optimizier kullanılarak iki girdiye (T, G), tek hedefe (Vmp) ve iki gizli katmana (64 ve 32 birim) sahip zaman serisi veri odaklı yaklaşımlardır. DNN tarafından çıkarılan Vmp, gerçek Vpv ile karşılaştırılır ve hata sinyali, yükseltici tip DC-DC dönüştürücü çıkış voltajını giriş voltajına (Vpv) göre kontrol etmek için görev döngüsünü ayarlayan bir PI denetleyicisine verilir. Önerilen stack LSTM MPPT'nin yükseltici tip bir DC-DC dönüştürücü ile entegre edilmiş yüksek verimliliği göz önüne alındığında, DC bağlantı voltajının 800V'luk bir referansa göre düzenlenmiş kontrolünü sağlar. Ayrıca, bağımsız PI kontrolörlerine sahip 3 seviyeli nötr nokta kenetli (NPC) inverter kontrolü, güç şebekesiyle sorunsuz entegrasyon sağlamak için DC bara voltajının hassas bir şekilde düzenlenmesini sağlar. Özellikle, önerilen LSTM MPPT, PV dizisinden 98,7 kW güç çekmekte ve NPC inverter kontrolü ile 98,4kW aktif gücü şebekeye aktarmaktadır. Bu şekilde, güç kalitesinin dağıtılmış enerji kaynaklarının ve mikro şebekelerin şebeke ara bağlantısına yönelik uluslararası standartlara uygun olmasını sağlarken %99'un üzerinde bir güç aktarım verimliliği elde edilmektedir.

**Anahtar Kelimeler:** Güneş Fotovoltaik Sistemi, Maksimum Güç Noktası İzleme Kontrolü, Yükseltici tip DC-DC dönüştürücü, NPC Şebekeye Bağlı İnvertör, Yapay Zekâ, Derin Öğrenme, Uzun Kısa Süreli Bellek Ağı, Derin Sinir Ağı.



## **ABSTRACT**

### **PH.D. THESIS**

## **ARTIFICIAL INTELLIGENCE BASED HYBRID CONTROL OF SOLAR PHOTOVOLTAIC SYSTEM FOR DISTRIBUTED POWER GENERATION**

**Umair YOUNAS**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
SELÇUK UNIVERSITY**

**THE DEGREE OF DOCTOR OF PHILOSOPHY IN ELECTRICAL AND  
ELECTRONICS ENGINEERING**

**Advisor: Prof. Dr. Ahmet Afşin KULAKSIZ**

**2024, 178 Pages**

### **Jury**

**Prof. Dr. Ahmet Afşin KULAKSIZ**

**Prof. Dr. Ömer AYDOĞDU**

**Prof. Dr. Bahadır AKBAL**

**Assoc. Prof. Hulusi KARACA**

**Assoc. Prof. Mümtaz MUTLUER**

Rising energy demand from urbanization and population growth coupled with the need to mitigate greenhouse gas emissions is driving energy markets toward renewable energy sources such as solar photovoltaics (PV). However, solar panel efficiency is limited (15-25%) and output power fluctuates with temperature (T) and irradiance (G) changes, constraining grid-tied PV applications. To address these challenges, this thesis presents a supervised deep learning long short-term memory (LSTM) network as a maximum power point tracking (MPPT) control for a 100-kW grid-connected PV system. The LSTM-based MPPT is compared to a feedforward deep neural network (FF-DNN) and conventional perturb and observe (P&O) MPPT using Simulink MATLAB. Performance of DL based MPPT controllers is evaluated via mean square error, root mean square error, mean average error, R2 score and power prediction error. Initially, one million data points are collected and pre-processed (z-score normalization), and visualized (bar charts, histogram, and correlation matrix) before an 80/20 split into training and test sets. The LSTM and FF-DNN are time series data driven approaches that have two inputs (T, G), single target ( $V_{mp}$ ), and two hidden layers (64 and 32 units), using the Adam optimizer. The DNN extracted  $V_{mp}$  is compared to actual  $V_{pv}$  and the error signal is given to a PI controller, which adjusts the duty cycle to control the DC-DC boost converter output voltage with respect to the input voltage ( $V_{pv}$ ). Given the high efficiency of the proposed stacked LSTM MPPT integrated with a DC-DC boost converter enables regulated control of the DC link voltage to a reference of 800V. Furthermore, a 3-level neutral point clamped (NPC) inverter with independent PI controllers allows precise regulation of the DC bus voltage to ensure seamless integration with the power grid. In particular, the proposed LSTM MPPT draws 98.7 kW of power from the PV array and, together with the NPC inverter control, transfers 98.4kW of active power to the grid. In this way, a power transfer efficiency of over 99% is achieved while ensuring that the power quality complies with international standards for grid interconnection of distributed energy resources and microgrids.

**Keywords:** Solar Photovoltaic System, Maximum Power Point Tracking Control, Boost Converter, NPC Grid-Tied Inverter, Artificial Intelligence, Deep Learning, Long Short-Term Memory Network, Deep Neural Network.

## ÖNSÖZ

Öncelikle, bu dönüm noktasına ulaşmam için bana bilgelik ve cesaret verdiği için Allah'a şükrediyorum. Danışmanım Prof. Dr. Ahmet KULAKSIZ'a doktora yolculuğum boyunca değerli rehberliği, desteği, olumlu geri bildirimi ve teşviki için en derin şükranlarımı sunarım. Kendisinin araştırma ve bilgiye olan tutkusu büyük bir ilham kaynağı olmuştur. Komite üyelerim Konya Teknik Üniversitesi'nden Prof. Dr. Ömer AYDOĞDU ve Selçuk Üniversitesi'nden Doç. Dr. Hulusi KARACA'ya destekleri, tavsiyeleri ve araştırmamı genişletmem için beni motive ettikleri için teşekkürlerimi sunarım.

İlkokuldan doktora eğitimime kadar tüm hocalarıma, özellikle yüksek lisans araştırmamı destekleyen ve doktora yolculuğumun temelini atan COMSATS Üniversitesi'nden Doç. Dr. Bilal Khan ve İtalya Sannio Üniversitesi'nden Prof. Dr. Alfredo Vaccaro'ya en içten şükranlarımı sunarım. YTB (Yurt Disi Türkleri ve Akraba Topluluğu) - Türkiye Bursları'na doktora yolculuğum boyunca verdikleri tüm finansal destek için minnettarım. Dr. Akif Durdu'ya desteği ve Konya Teknik Üniversitesi'ndeki RACLAB'a erişimi için teşekkür ederim. Bu laboratuvar erişimi, araştırma çalışmalarımı başarıyla yürütmemi ve tezimi zamanında tamamlamamı sağladı.

Babam Muhammad Younas ve annem Bibi Mukhtiar, koşulsuz destekleriyle her adımda yanımda durarak sevgi ve güç kaynağı oldular. Ayrıca iki ağabeyime (Qasir Mehmood ve Yasir Mehmood), iki küçük ikiz kardeşime (Anees & Awais) ve 3 kız kardeşime (Saima, Ruqayya ve Sidra Bajiz) maddi ve manevi destekleri, sevgileri, inançları ve cesaretlendirmeleri için teşekkür etmek isterim. Sevgili eşime (Uzma Bibi) ve değerli kızıma (Manahil Umair) özel teşekkürler, bana olan sarsılmaz sevginiz ve inancınız bu uzun yolculukta en zorlu anlarda sebat etmeme yardımcı oldu. Ayrıca tüm arkadaşlarıma değerli dostlukları ve destekleri için teşekkür ederim.

Son olarak TÜRKİYE'ye en derin şükranlarımı sunmak istiyorum- bu sevgili ülke beni kollarını açarak karşıladı ve bana aydınlatıcı yeni bir yaşam deneyimi hediye etti. TÜRKİYE bana sabırla melodik dilini öğretti, zengin kültürünü derinlemesine anlamamı sağladı, ilham verici yeni ufuklar keşfetmeme yardımcı oldu ve beni kendilerinden biri olarak sevgiyle kucakladı. Doktora yolculuğumu hem akademik hem de kişisel olarak olağanüstü tatmin edici hale getirdiği için TÜRKİYE'ye sonsuza dek borçluyum.

Bu doktora yolculuğu hem kişisel hem de profesyonel düzeyde son derece ödüllendirici oldu. Bu dönüm noktasına ulaşmamda oynadıkları etkili rol için yukarıda adı geçen herkese derin bir minnet borcum var. Yol boyunca bana destek olan herkese sonsuza kadar minnettar kalacağım.

Umair YOUNAS  
KONYA-2024

## İÇİNDEKİLER

|                                                                             |             |
|-----------------------------------------------------------------------------|-------------|
| <b>ÖZET .....</b>                                                           | <b>iv</b>   |
| <b>ABSTRACT.....</b>                                                        | <b>v</b>    |
| <b>ÖNSÖZ .....</b>                                                          | <b>vi</b>   |
| <b>SİMGELER VE KISALTMALAR .....</b>                                        | <b>x</b>    |
| <b>ŞEKİLLER LİSTESİ .....</b>                                               | <b>xiii</b> |
| <b>ÇİZELGE LİSTESİ.....</b>                                                 | <b>xvii</b> |
| <b>1. GİRİŞ.....</b>                                                        | <b>1</b>    |
| 1.1. Araştırma Altyapısı .....                                              | 1           |
| 1.2. Araştırma Motivasyonu.....                                             | 5           |
| 1.3. Araştırma Hedefleri.....                                               | 7           |
| 1.4. Araştırma Katkıları.....                                               | 8           |
| 1.5. Tez Organizasyonu.....                                                 | 9           |
| <b>2. KAYNAK ARAŞTIRMASI .....</b>                                          | <b>13</b>   |
| 2.1. Şebekeye Bağlı PV'nin İlk Aşamasına İlişkin Literatür Taraması.....    | 14          |
| 2.1.1. Geleneksel MPPT Yöntemlerine İlişkin Literatür Taraması .....        | 14          |
| 2.1.2. Akıllı MPPT Yöntemlerine İlişkin Literatür Taraması.....             | 16          |
| 2.1.3. Hibrit MPPT Yöntemlerine İlişkin Literatür Taraması .....            | 18          |
| 2.1.4. AI, ML ve DL tabanlı MPPT Yöntemlerinin Literatür İncelemesi .....   | 20          |
| AI ML DL tabanlı MPPT Algoritmaları.....                                    | 26          |
| 2.2. Şebekeye Bağlı PV'nin İkinci Aşamasına İlişkin Literatür Taraması..... | 27          |
| 2.3. Geçmişteki Zorluklar ve Önerilen Lstm Tabanlı Mppt'nin Kapsamı .....   | 29          |
| <b>3. MATERYAL VE YÖNTEM.....</b>                                           | <b>34</b>   |
| 3.1. Şebekeye Bağlı PV Sistemin İlk Aşaması .....                           | 35          |
| 3.1.1. Solar PV Panel .....                                                 | 35          |
| 3.1.2. Yükseltici tip DC-DC dönüştürücünün Formülasyonu ve Tasarımı .....   | 40          |
| 3.1.3. Maksimum Güç Noktası Takip Kontrolörü .....                          | 45          |
| 3.2. Şebeke Bağlantılı PV Sisteminin İkinci Aşaması .....                   | 58          |
| 3.2.1. Şebekeye Bağlı İnverterlere Genel Bakış .....                        | 59          |
| 3.2.2. İnverter Kontrol Topolojileri .....                                  | 60          |
| 3.2.3. İnverter Kontrol Mimarileri (İnverter Çeşitleri) .....               | 63          |
| 3.2.4. İnverter Kontrolü .....                                              | 65          |
| 3.2.5. Şebekeye Bağlı PV İnverterin Kademeli Kontrolü.....                  | 69          |
| 3.2.6. Şebekeye Bağlı PV Sistem için LCL Filtre Tasarımı .....              | 71          |
| 3.3. Bölüm Özeti .....                                                      | 73          |
| <b>4. ÖNERİLEN ARAŞTIRMA .....</b>                                          | <b>74</b>   |
| 4.1. LSTM Ağlarının Girişi.....                                             | 75          |

|         |                                                               |            |
|---------|---------------------------------------------------------------|------------|
| 4.1.1.  | LSTM Ağlarına Genel Bakış .....                               | 75         |
| 4.1.2.  | LSTM Ağının Uygulamaları.....                                 | 76         |
| 4.2.    | LSTM Ağ Mimarisi.....                                         | 78         |
| 4.2.1.  | Bir LSTM Hücresinin Kapıları (Gates) .....                    | 78         |
| 4.2.2.  | LSTM Hücresinde Hücre Durumu (Bellek Hücresi).....            | 81         |
| 4.3.    | LSTM Ağları İçin Aktivasyon Fonksiyonları .....               | 82         |
| 4.3.1.  | Doğrultulmuş Doğrusal Birim (RELU) Aktivasyon Fonksiyonu..... | 83         |
| 4.3.2.  | Sigmoid Aktivasyon Fonksiyonu.....                            | 84         |
| 4.3.3.  | Hiperbolik Tanjant Aktivasyon Fonksiyonu.....                 | 84         |
| 4.4.    | LSTM Ağının Hiperparametreleri.....                           | 85         |
| 4.5.    | LSTM Ağının Türleri .....                                     | 86         |
| 4.5.1.  | Tek katmanlı LSTM.....                                        | 87         |
| 4.5.2.  | Stack LSTM.....                                               | 87         |
| 4.5.3.  | Çift Yönlü LSTM.....                                          | 87         |
| 4.5.4.  | CNN-LSTM .....                                                | 88         |
| 4.5.5.  | Dikkat tabanlı LSTM .....                                     | 88         |
| 4.5.6.  | Multimodal LSTM.....                                          | 88         |
| 4.6.    | Önerilen Stack LSTM Ağı .....                                 | 88         |
| 4.6.1.  | Geliştirilmiş Model Performansı .....                         | 89         |
| 4.6.2.  | Uzun Vadeli Bağımlılıkların Yakalanması.....                  | 89         |
| 4.6.3.  | Hiyerarşik Temsil .....                                       | 89         |
| 4.6.4.  | Esneklik ve Uyarlanabilirlik .....                            | 90         |
| 4.7.    | Solar PV Sistemi İçin MPPT Olarak LSTM Stack .....            | 90         |
| 4.7.1.  | Önerilen Solar PV Sistemine Genel Bakış .....                 | 90         |
| 4.7.2.  | Solar PV Sisteminde MPPT'ye Genel Bakış .....                 | 94         |
| 4.8.    | MPPT Kontrolörü Olarak Önerilen Stack LSTM .....              | 95         |
| 4.9.    | LSTM'yi Geleneksel MPPT ile Karşılaştırma.....                | 96         |
| 4.10.   | LSTM Ağının Eğitimi .....                                     | 97         |
| 4.10.1. | Veri Ön İşleme .....                                          | 98         |
| 4.10.2. | Veri Toplama .....                                            | 98         |
| 4.10.3. | LSTM'nin Tanımlayıcı Yapısı .....                             | 101        |
| 4.10.4. | Eğitim Seçeneklerinin Yapılandırılması .....                  | 102        |
| 4.10.5. | LSTM Ağının Eğitimi .....                                     | 105        |
| 4.11.   | LSTM Ağının Test Edilmesi .....                               | 106        |
| 4.11.1. | Eğitilmiş LSTM Ağının Değerlendirilmesi .....                 | 106        |
| 4.11.2. | Eğitim ve Test Hatalarının Görselleştirilmesi.....            | 106        |
| 4.12.   | Performans Değerlendirme Metriklerinin Seçimi .....           | 107        |
| 4.12.1. | Ortalama Kare Hata (MSE).....                                 | 107        |
| 4.12.2. | Kök Ortalama Kare Hata (RMSE) .....                           | 108        |
| 4.12.3. | Ortalama Mutlak Hata (MAE) .....                              | 108        |
| 4.12.4. | R-kare (R <sup>2</sup> ) veya Belirleme Katsayısı .....       | 109        |
| 4.12.5. | Doğrulama Kaybı .....                                         | 109        |
| 4.13.   | Şebekeye Bağlı PV Sistem İçin Üç Fazlı İnverter.....          | 110        |
| 4.13.1. | NPC İnvertöre Genel Bakış.....                                | 110        |
| 4.13.2. | NPC İnvertör Tasarımı .....                                   | 111        |
| 4.13.3. | NPC İnverterin Çalışması .....                                | 111        |
| 4.14.   | Bölüm Özeti.....                                              | 113        |
| 5.      | <b>SONUÇLAR VE TARTIŞMA .....</b>                             | <b>115</b> |

|                                                                                           |            |
|-------------------------------------------------------------------------------------------|------------|
| 5.1. Veri Toplama .....                                                                   | 116        |
| 5.1.1. Tam Girdi Veri Seti .....                                                          | 116        |
| 5.1.2. Eğitim Veri Seti .....                                                             | 117        |
| 5.1.3. Test Veri Seti .....                                                               | 118        |
| 5.2. Veri Ön İşleme ve Normalleştirme .....                                               | 119        |
| 5.2.1. Eğitim Verilerinin Normalleştirilmesi .....                                        | 120        |
| 5.2.2. Test Verilerinin Normalizasyonu.....                                               | 121        |
| 5.3. Veri Görselleştirme .....                                                            | 122        |
| 5.3.1. Kutu Grafikleri ve Histogram Tabanlı Veri Görselleştirme .....                     | 123        |
| 5.3.2. Korelasyon Tabanlı Veri Görselleştirme .....                                       | 124        |
| 5.4. DL Tabanlı MPPT Modelinin Eğitimi .....                                              | 126        |
| 5.4.1. DNN tabanlı MPP Ağ Eğitimi .....                                                   | 127        |
| 5.4.2. LSTM tabanlı MPP Ağ Eğitimi .....                                                  | 132        |
| 5.4.3. DNN ve LSTM Modellerinin Performans Değerlendirme Karşılaştırması<br>138           |            |
| 5.5. Şebekeye Bağlı PV için MPPT Kontrolü.....                                            | 140        |
| 5.5.1. Simulink'te Şebekeye Bağlı PV Sistemin MPPT'si için Giriş Sinyalleri               | 142        |
| 5.5.2. G ve T Sinyallerine Karşı Solar PV Ölçümü.....                                     | 144        |
| 5.5.3. Stack LSTM, FF-DNN ve P&O MPPT Kontrolörlerinin Karşılaştırmalı<br>Sonuçları ..... | 145        |
| 5.5.4. Birinci Aşamada MPPT Entegre Yükseltici tip DC-DC dönüştürücü Çıkış<br>Gerilimi    | 147        |
| 5.6. Şebekeye Bağlı PV'nin İnverter Kontrolü.....                                         | 148        |
| 5.6.1. NPC İnvertörün Giriş (DC Link) ve Çıkış Gerilimi .....                             | 150        |
| 5.6.2. Değişken Girişlere (G, T) Göre Şebeke Gerilimi ve Akımı .....                      | 153        |
| 5.6.3. Direkt ve Kuadratür Eksen Akımları .....                                           | 153        |
| 5.6.4. PV Entegre Şebekeye Sağlanan Aktif Reaktif Güç .....                               | 154        |
| 5.7. Bölüm Özeti .....                                                                    | 156        |
| <b>6. SONUÇLAR VE ÖNERİLER .....</b>                                                      | <b>157</b> |
| 6.1. Sonuçlar.....                                                                        | 157        |
| 6.2. Öneriler .....                                                                       | 161        |
| <b>KAYNAKLAR .....</b>                                                                    | <b>163</b> |

## SİMGELER VE KISALTMALAR

### Simgeler

|                   |                                                     |
|-------------------|-----------------------------------------------------|
| A                 | : Amper                                             |
| V                 | : Volt                                              |
| W                 | : Watt                                              |
| VAR               | : Reaktif amper volt                                |
| Pu                | : Birim başına                                      |
| H                 | : Henry                                             |
| s                 | : Saniye                                            |
| M                 | : Mega                                              |
| t                 | : Zaman                                             |
| $V_{dc}, V_{bus}$ | : Bara gerilimi                                     |
| $I_a, I_b, I_c$   | : Üç faz akım bileşenleri                           |
| $V_a, V_b, V_c$   | : Üç faz gerilim bileşenleri                        |
| $I_d, I_q$        | : d-q akım bileşenleri                              |
| $V_d, V_q$        | : d-q gerilim bileşenleri                           |
| N                 | : Toplam örnek sayısı                               |
| $V_{mp}$          | : Maksimum güç noktalarında gerilim                 |
| $\hat{V}_{mp}$    | : Maksimum güç noktasında tahmin edilen gerilim     |
| $I_{mp}$          | : Maksimum güç noktalarında akım                    |
| T                 | : Zaman periyodu                                    |
| $P_{mp}$          | : Maksimum güç noktasında güç                       |
| $P_{max}$         | : Maksimum Güç                                      |
| T                 | : Güneş hücresi sıcaklığı                           |
| $T_s$             | : STC'de güneş hücresinin sıcaklığı                 |
| G                 | : Güneş Işınımı                                     |
| $G_s$             | : STC'de güneş ışıınımı                             |
| $G_{min}$         | : Minimum güneş ışıınımı                            |
| $G_{max}$         | : Maksimum güneş ışıınımı                           |
| $T_{min}$         | : Minimum hücre sıcaklığı                           |
| $T_{max}$         | : Maksimum hücre sıcaklığı                          |
| $\alpha$          | : $I_{sc}$ için Sıcaklık Katsayısı                  |
| $\beta$           | : $V_{oc}$ için Sıcaklık Katsayısı                  |
| K                 | : Boltzmann sabiti ( $1.38 * 10^{-23} \text{J/K}$ ) |
| $V_{oc}$          | : Açık devre gerilimi                               |
| $N_s$             | : Seri bağlı modül sayısı                           |
| $N_p$             | : Paralel bağlı modül sayısı                        |
| $X_t$             | : DL ağının t zamanındaki girdi değeri              |
| $h_t$             | : Gizli katmanın t zamanındaki çıktısı              |
| $O_t$             | : DL ağının t zamanındaki çıktı                     |
| R                 | : Direnç                                            |
| L                 | : Endüktans                                         |
| C                 | : kapasitans                                        |
| Z                 | : Empedans                                          |
| $V_m$             | : Gerilim referans sinyalinin genliği               |
| $V_c$             | : Gerilim taşıyıcı sinyalin genliği                 |

|                 |                                               |
|-----------------|-----------------------------------------------|
| $m_a$           | : Modülasyon indeksi                          |
| $V_{pv}$        | : PV gerilim                                  |
| $V_{dc}$        | : DC-link gerilim                             |
| $D$             | : Görev döngüsü                               |
| $R_s$           | : Seri direnci                                |
| $R_{sh}$        | : Şönt direnci                                |
| $I_o$           | : PV hücresinden geçen toplam akım            |
| $I_{ph}$        | : PV hücre fotovolttaik akımı                 |
| $I_d$           | : PV hücre diyot akımı                        |
| $I_{sh}$        | : PV hücre şönt akımı                         |
| $q$             | : Elektron yük sabiti ( $1,602 * 10^{-23}C$ ) |
| $A$             | : İdeallik faktörü                            |
| $I_{sc}$        | : Kısa devre akımı                            |
| $V_{oc}$        | : Açık devre gerilimi                         |
| $V_i$           | : Giriş gerilimi                              |
| $V_o$           | : Çıkış gerilimi                              |
| $I_i$           | : Giriş akımı                                 |
| $I_o$           | : Çıkış akımı                                 |
| $\Delta IL$     | : İndüktör Dalgalanma Akımı                   |
| $\Delta VC$     | : Kondansatör Dalgalanma Gerilimi             |
| $f_{sw}$        | : Anahtarlama frekansı                        |
| $\sigma, \tanh$ | : sigmoid ve tanh aktivasyon fonksiyonu       |
| $I_d, I_q$      | : D ve q eksen akımı                          |
| $V_d, V_q$      | : D ve q eksen gerilim                        |
| $f_{res}$       | : Rezonans frekansı                           |
| $\xi$           | : Sönümlleme oranı                            |
| $f_t$           | : Unut kapısının t zamanındaki çıkışı         |
| $h_{t-1}$       | : Önceki gizli durumun çıktısı                |
| $W$             | : Ağırlık                                     |
| $b$             | : bias                                        |
| $i_t$           | : Giriş kapısının t zamanındaki çıkışı        |
| $C_t$           | : t zamanındaki hücre durumu                  |

## Kısaltmalar

|                |                                            |
|----------------|--------------------------------------------|
| RES            | : Yenilenebilir Enerji Kaynakları          |
| PV             | : Fotovoltaik                              |
| G              | : Güneşlenme Oranı                         |
| T              | : Sıcaklık                                 |
| STC            | : Standart Test Koşulları                  |
| MPP            | : Maksimum Güç Noktası                     |
| MPPT           | : Maksimum Güç Noktası Takibi              |
| P&O            | : Pertürbasyon ve Gözlem                   |
| IC             | : Artan İletkenlik                         |
| FLC            | : Bulanık Mantık Denetleyicisi             |
| PSO            | : Parçacık Sürü Optimizasyonu              |
| GA             | : Genetik Algoritma                        |
| SMC            | : Kayan Mod Kontrolü                       |
| ANFIS          | : Yapay Sinir Ağı Bulanık çıkarım Sistemi  |
| DC             | : Doğrudan Akım                            |
| AC             | : Alternatif Akım                          |
| AI             | : Yapay Zekâ                               |
| ML             | : Makine Öğrenmesi                         |
| DL             | : Derin Öğrenme                            |
| SL             | : Denetimli Öğrenme                        |
| USL            | : Denetimsiz öğrenme                       |
| RL             | : Pekiştirmeli öğrenme                     |
| ANN            | : Yapay Sinir Ağı                          |
| CNN            | : Evrişimsel Sinir Ağı                     |
| FFN            | : İleri Beslemeli Ağ                       |
| DNN            | : Derin Sinir Ağı                          |
| RNN            | : Tekrarlayan Sinir Ağı                    |
| LSTM           | : Uzun Kısa Süreli Hafıza Ağı              |
| SGD            | : Stokastik Gradyan İnişi                  |
| MSE            | : Ortalama Kare Hata                       |
| RMSE           | : Kök Ortalama Kare Hata                   |
| MAE            | : Ortalama Mutlak Hata                     |
| R <sup>2</sup> | : Düzenleme                                |
| RELU           | : Doğrultucu Lineer Birim Fonksiyonu       |
| PWM            | : Darbe Genişlik Modülasyonu               |
| SVM            | : Uzay Vektör Modülasyonu                  |
| D              | : Görev Döngüsü                            |
| VSI            | : Gerilim Kaynaklı İnverter                |
| CSI            | : Akım Kaynaklı İnverter                   |
| IGBT           | : Yalıtılmış Kapı İki Kutuplu Transistör   |
| PLL            | : Faz Kilitli Döngü                        |
| THD            | : Toplam Harmonik Bozulma                  |
| NREL           | : Ulusal Yenilenebilir Enerji Laboratuvarı |
| ESRA           | : Enerji Sistemleri Araştırma Derneği      |
| WRDC           | : Rüzgâr Araştırma Geliştirme Merkezi      |
| TEİAŞ          | : Türkiye Elektrik İletim A.Ş.             |
| NEPRA          | : Ulusal Elektrik Güç Düzenleme Kurumu     |



## ŞEKİLLER LİSTESİ

|                                                                                                                          |    |
|--------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 1.1. Elektrik enerjisi kaynaklarının başlıca küresel üretim katkısı .....                                          | 2  |
| Şekil 1.2. 2001-2003 yılları arasında küresel PV enerji kurulumu .....                                                   | 3  |
| Şekil 1.3. Bir PV hücresinin, PV modülünün ve PV dizisinin gösterimi.....                                                | 4  |
| Şekil 1.4. Önerilen 100 kW şebekeye bağlı PV sisteminin tek hat şeması .....                                             | 5  |
| Şekil 1.5. Tüm bölümlerin ana temalarını ve katkılarını vurgulayarak tez organizasyonuna genel bakış .....               | 10 |
| Şekil 2.1. AI, ML ve DL'nin temel tanıtımı ve karşılaştırılması.....                                                     | 21 |
| Şekil 2.2. ML'nin, türlerinin ve türleri arasındaki farkların gösterilmesi .....                                         | 22 |
| Şekil 2.3. Pekiştirmeli öğrenme (RL) algoritmasının çalışma akışı .....                                                  | 22 |
| Şekil 3.1. Önerilen araştırmanın birinci ve ikinci aşamasında kullanılan bileşenler .....                                | 34 |
| Şekil 3.2. Solar PV hücresinin çalışma prensibi .....                                                                    | 36 |
| Şekil 3.3. Bir PV hücresinin tek diyot modeli .....                                                                      | 37 |
| Şekil 3.4. Bir yükseltici tip DC-DC dönüştürücünün şematik diyagramı.....                                                | 40 |
| Şekil 3.5. Anahtar ON (kapalı) olduğunda yükseltici tip DC-DC dönüştürücünün çalışması....                               | 42 |
| Şekil 3.6. Anahtar OFF (açık) olduğunda yükseltici tip DC-DC dönüştürücünün çalışması .....                              | 42 |
| Şekil 3.7. MPPT'nin yükseltici tip DC-DC dönüştürücünün anahtarının görev döngüsünü kontrol etmesinin gösterilmesi ..... | 46 |
| Şekil 3.8. G ve T değerlerindeki değişimlerin PV dizisinin PV eğrisi üzerindeki etkisi .....                             | 46 |
| Şekil 3.9. PV eğrisi üzerinde MPP'yi çıkarmak için P&O yönteminin çalışma prensibi.....                                  | 47 |
| Şekil 3.10. P&O MPPT kontrolörünün akış şeması ve örnek MATLAB kodu.....                                                 | 48 |
| Şekil 3.11. Tek bir nöronun temel yapısı .....                                                                           | 50 |
| Şekil 3.12. Tüm ANN, ML ve DL ağlarının çalışma sürecini temsil eden akış şeması .....                                   | 54 |
| Şekil 3.13. Bir RNN'nin yapısı ve katlanmamış açıklaması .....                                                           | 56 |
| Şekil 3.14. Önerilen araştırmanın ikinci aşamasında akım ve gerilim kontrolörünün gösterilmesi .....                     | 59 |

|                                                                                                                                             |     |
|---------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Şekil 3.15.</b> Literatürde kullanılan inverter topolojileri .....                                                                       | 61  |
| <b>Şekil 3.16.</b> (a) gerilim kaynaklı inverter ve (b) akım kaynaklı inverterin blok diyagram gösterimi.....                               | 64  |
| <b>Şekil 3.17.</b> Tek fazlı sinüzoidal PWM'nin anahtarlama sinyalleri.....                                                                 | 66  |
| <b>Şekil 3.18.</b> PLL senkronizasyon devresinin yapısı .....                                                                               | 67  |
| <b>Şekil 3.19.</b> Gerilim ve akım kontrol döngüsünün çalışmasını gösteren şematik diyagram .....                                           | 70  |
| <b>Şekil 4.1.</b> LSTM hücresi ile örneklendirilen temel LSTM bileşeninin ağ yapısı .....                                                   | 78  |
| <b>Şekil 4.2.</b> Bir LSTM hücresindeki üç kapının her birinin ayrı ayrı vurgulanması.....                                                  | 81  |
| <b>Şekil 4.3.</b> Birkaç önemli aktivasyon fonksiyonunun grafiksel gösterimi (a) Sigmoid, (b) Tanh ve (c) RELU aktivasyon fonksiyonu.....   | 83  |
| <b>Şekil 4.4.</b> Önerilen araştırmada şebekeye bağlı PV dizisinin birinci ve ikinci aşamalarını da gösteren eksiksiz şematik diyagram..... | 91  |
| <b>Şekil 4.5.</b> Bir LSTM ağının eğitim sürecinin kontrol akışı.....                                                                       | 99  |
| <b>Şekil 4.6.</b> Üç fazlı NPC gerilim kaynaklı dönüştürücünün şematik diyagramı .....                                                      | 111 |
| <b>Şekil 5.1.</b> Her biri 1 milyon veri noktası içeren tam girdi ve hedef veri seti .....                                                  | 117 |
| <b>Şekil 5.2.</b> Toplam veri örneklerinin ilk %80'ini içeren eğitim veri seti .....                                                        | 118 |
| <b>Şekil 5.3.</b> Toplam veri örneklerinin son %20'sini içeren test veri seti .....                                                         | 119 |
| <b>Şekil 5.4.</b> Ham eğitim veri setine uygulanan Z-skor normalizasyonu .....                                                              | 120 |
| <b>Şekil 5.5.</b> Ham test veri setine uygulanan Z-skor normalizasyonu.....                                                                 | 121 |
| <b>Şekil 5.6.</b> Normalleştirilmemiş verilerin kutu grafiği ve histogram tabanlı görselleştirilmesi .                                      | 123 |
| <b>Şekil 5.7.</b> Normalleştirilmiş verilerin kutu grafiği ve histogram tabanlı görselleştirilmesi .....                                    | 124 |
| <b>Şekil 5.8.</b> Normalleştirilmiş ve ham girdilerin (G, T) ve hedef (Vmp) verilerin korelasyon matrisi .....                              | 126 |
| <b>Şekil 5.9.</b> 64 ve 32 birimlik iki gizli katmana sahip ileri beslemeli DNN mimarisi .....                                              | 127 |
| <b>Şekil 5.10.</b> FF DNN Ağının artan epoklarla eğitim ilerleme durumu.....                                                                | 130 |

|                                                                                                                                                                          |     |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Şekil 5.11.</b> (a) normalize edilmiş girdiler, (b) tahmin edilen değer ve (c) FF DNN kullanılarak gerçek ve tahmin edilen hedef Vmp arasındaki eğitim hatası.....    | 130 |
| <b>Şekil 5.12.</b> (a) Test girdileri, (b) tahmin edilen test ve (c) FF DNN kullanılarak gerçek ve tahmin edilen hedef Vmp arasındaki test hatası.....                   | 132 |
| <b>Şekil 5.13.</b> MATLAB'ın Derin Ağ Tasarımcısı Araç Kutusunda LSTM katmanlarının gösterimi .....                                                                      | 133 |
| <b>Şekil 5.14.</b> Derin Ağ Tasarımcısında LSTM katmanlarının sırası.....                                                                                                | 134 |
| <b>Şekil 5.15.</b> LSTM ağının artan epoklarla eğitim ilerlemesi .....                                                                                                   | 136 |
| <b>Şekil 5.16.</b> LSTM kullanarak (a) eğitim girdileri, (b) tahmin edilen hedef ve (c) gerçek ve tahmin edilen hedef Vmp arasındaki eğitim hatası .....                 | 137 |
| <b>Şekil 5.17.</b> (a) Test girdileri, (b) gerçek test hedefine karşı öngörülen hedef ve (c) LSTM kullanılarak gerçek ve öngörülen hedef Vmp arasındaki test hatası..... | 138 |
| <b>Şekil 5.18.</b> Her iki DL (DNN ve LSTM) Ağı arasındaki performans karşılaştırma analizi. ....                                                                        | 140 |
| <b>Şekil 5.19.</b> 100 kW şebekeye bağlı PV sisteminin Simulink modeli.....                                                                                              | 140 |
| <b>Şekil 5.20.</b> Şebekeye bağlı PV sistemindeki tüm sinyallerin görselleştirilmesi ve çizilmesi ...                                                                    | 141 |
| <b>Şekil 5.21.</b> Simulink ortamında MPPT kontrolörlerine (LSTM, DNN, P&O) G ve T giriş sinyalleri.....                                                                 | 142 |
| <b>Şekil 5.22.</b> Değişken girişlere (G, T) göre solar PV modül çıkışları (V, I, P) .....                                                                               | 144 |
| <b>Şekil 5.23.</b> Stack LSTM, FF-DNN ve P&O MPPT Kontrolörleri arasında karşılaştırmalı analiz .....                                                                    | 146 |
| <b>Şekil 5.24.</b> STC'de LSTM, DNN ve P&O MPPT Kontrolörleri arasındaki maksimum güç çıkarma karşılaştırması. ....                                                      | 146 |
| <b>Şekil 5.25.</b> Değişken girişlere (G, T) göre PV dizinin hedef gerilimi, görev döngüsü ve yükseltme gerilimi.....                                                    | 147 |
| <b>Şekil 5.26.</b> Şebekeye bağlı inverter kontrolünün Simulink modeli .....                                                                                             | 148 |
| <b>Şekil 5.27.</b> 3 seviyeli NPC inverterin çıkışındaki 3 fazlı voltaj ve akım. ....                                                                                    | 151 |
| <b>Şekil 5.28.</b> İnverterin çıkışındaki faz hattı voltajı ve akımı. ....                                                                                               | 152 |

|                                                                                                 |     |
|-------------------------------------------------------------------------------------------------|-----|
| <b>Şekil 5.29.</b> İnverter kontrol bölümünde d eksen ve q eksen akımlarının gösterilmesi ..... | 154 |
| <b>Şekil 5.30.</b> PV dizisinden mikro şebekeye aktarılan aktif ve reaktif güç .....            | 155 |



## ÇİZELGE LİSTESİ

|                                                                                                                                  |     |
|----------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Çizelge 2.1.</b> ML ve DL modellerinin karakteristik özelliklerinin karşılaştırılması .....                                   | 23  |
| <b>Çizelge 2.2.</b> Tüm geleneksel, akıllı, hibrit, ML ve DL tabanlı MPPT kontrol yöntemlerinin özellikleri .....                | 26  |
| <b>Çizelge 2.3.</b> Yaygın olarak kullanılan MPPT yöntemleri arasında kısa bir karşılaştırma .....                               | 32  |
| <b>Çizelge 3.1.</b> Önerilen PV dizisinin tasarım parametreleri.....                                                             | 39  |
| <b>Çizelge 3.2.</b> Yükseltici tip DC-DC dönüştürücünün tasarım parametreleri.....                                               | 44  |
| <b>Çizelge 3.3.</b> Şebekeye Bağlı PV Sistemler için inverter topolojilerinin karşılaştırmalı analizi..                          | 60  |
| <b>Çizelge 4.1.</b> Önerilen LSTM'de kullanılan hiperparametrelerin listesi.....                                                 | 85  |
| <b>Çizelge 4.2.</b> Önerilen LSTM modelinin eğitimi için kullanılan eğitim seçenekleri .....                                     | 103 |
| <b>Çizelge 4.3.</b> NPC inverterin her fazındaki anahtarlama durumları ve karşılık gelen çıkış gerilimi .....                    | 112 |
| <b>Çizelge 5.1.</b> DNN ağının ağ tasarımı, hiperparametreleri ve performans endeksleri .....                                    | 129 |
| <b>Çizelge 5.2.</b> LSTM ağının ağ tasarımı, hiperparametreleri ve performans endeksleri .....                                   | 135 |
| <b>Çizelge 5.3.</b> Hem ham hem de normalleştirilmiş veriler için DNN ve LSTM performans parametrelerinin karşılaştırılması..... | 139 |

## 1. GİRİŞ


Bu tez, 100 kW'lık bir fotovoltaik sistemin, optimize edilmiş dağıtılmış güç üretimi için yapay zekâ (AI) tabanlı bir hibrit kontrolör kullanılarak bir elektrik mikro şebekesine entegrasyonunu ele almaktadır. Tezde kullanılan hibrit kavramı iki kontrolörün kombinasyonunu ifade etmektedir: (a) PV tarafında, Yapay Zeka (AI) kategorisine giren önerilen Derin Öğrenme (DL) tabanlı MPPT kontrolörü kullanılır, (b) şebeke tarafında, PV'nin DC gücünü AC'ye dönüştürmek ve şebeke entegrasyonuna uygun hale getirmek için düşüş (droop) kontrol olarak da bilinen ilgili PI kontrolörleri ile entegre edilmiş geleneksel akım ve gerilim kontrolörleri kullanılır. Merkezi olmayan bir PV kaynağı olarak, önerilen 100 kW'lık dağıtılmış güç üretimi yaklaşık 5 ev veya küçük bir endüstriyel tesisi besleyebilir. Önerilen sistem iki aşamada çalışmaktadır: İlk aşamada, 100 kW dağıtılmış güneş enerjisi üretilir ve bir stack LSTM tabanlı MPPT kontrolörü, yükseltici tip (boost) DC-DC dönüştürücünün kontrol sinyalini düzenleyerek ve 800 V DC'lik bir voltaj çıkışı sağlayarak maksimum güce ulaşır. İkinci aşamada 800 V DC, şebekeye entegre edilmiş üç fazlı 3 seviyeli bir NPC (Nötr Nokta Kenetli) inverter tarafından AC'ye dönüştürülür ve aktif güç şebekeye aktarılır. Genel olarak, bu hibrit yapay zekâ kontrol yaklaşımı, optimize edilmiş dağıtılmış solar PV üretimi ve sorunsuz şebeke entegrasyonu sağlar.

Bölüm 1, araştırma alanına kapsamlı bir giriş sunmakta, mevcut literatüre genel bir bakış sağlamakta, araştırma boşluklarını belirlemekte ve daha ileri araştırmalar için altyapı oluşturmaktadır. Araştırmanın kapsamı ve hedefleri tanımlanmakta, tezin yapısı özetlenmekte ve bölümün ana katkıları vurgulanarak sonuçlandırılmaktadır.

### 1.1. Araştırma Altyapısı

Küresel enerji talebi nüfus artışı, sanayileşme, kentleşme ve ekonomik kalkınma nedeniyle katlanarak artmaktadır (Rehman et al., 2022). Günümüzde, elektrik enerjisinin başlıca küresel üretimi, **Şekil 1.1'**de gösterildiği gibi, bu büyük enerji talebini karşılamak için yaklaşık yüzde 80'ini oluşturan kömür, petrol, doğal gaz ve nükleer enerji gibi geleneksel enerji kaynaklarına dayanmaktadır (*World Electricity Generation*, 2023). Ancak kömür, petrol ve doğal gaz gibi fosil yakıtlı enerji kaynakları zamanla tükenmekte, yüksek yakıt fiyatlarını korumakta ve 2030 yılına kadar yaklaşık 40,4 Gt CO<sub>2</sub> üretmesi

beklenen karbondioksit gibi büyük sera gazı emisyonlarına neden olmaktadır (Quadrelli & Peterson, 2007).




**Şekil 1.1.** Elektrik enerjisi kaynaklarının başlıca küresel üretim katkısı

Benzer şekilde, nükleer enerji sera gazı yaymadan büyük miktarlarda elektrik üretebilir, ancak yıkıcı kazalara neden olan radyoaktif atık üretir (Adamantiades & Kessides, 2009). Artan enerji talebiyle birlikte bu zorluklar daha belirgin hale gelmekte, güç kalitesi sorunları ve elektrik kesintilerine yol açmaktadır. ABD Hükümetine göre, elektrik kesintileri ve güç kalitesi sorunları Amerikan işletmelerine her yıl ortalama 100 milyar dolardan fazla zarara mal olmaktadır (Aggarwal et al., 2010). Geleneksel enerji ile ilgili sorunları çözmek için birçok çalışma yenilenebilir enerjilerin kullanılması çağrısında bulunmuştur. Bu nedenle, Yenilenebilir Enerji Kaynakları (RES) entegrasyonu son on yılda değerli bir araştırma konusu haline gelmiştir. Avrupa Birliği'nin Yenilenebilir Enerji Direktifi, 2030 yılına kadar toplam üretimin %32'sinden fazlasını ve 2050 yılına kadar %100'ünü yenilenebilir enerjilerden elde etmeyi hedeflemektedir (Shah et al., 2015).

Solar fotovoltaik (PV), rüzgâr enerjisi, hidroelektrik enerji, biyogaz, biyoenerji ve jeotermal enerji gibi RES'ler bol miktarda bulunur, doğal olarak yenilenebilir, sera gazı emisyonlarını azaltır ve hem merkezi hem de merkezi olmayan enerji sistemlerinin entegrasyonunu sağlar. RES'ler arasında güneş enerjisi ve rüzgar enerjisi, yazarların

(Qazi et al., 2019)'de belirttiği gibi hızla artan enerji talebinin üstesinden gelmek için yaygın olarak kullanılan RES'lerdir. RES'in çeşitli faydalarına rağmen, Işınım (G) ve Sıcaklık (T) gibi değişken ortam parametreleri nedeniyle enerji üretimindeki kesinti, şebekeye bağlı güç sistemlerinde uygulamalarını sınırlamaktadır. Bu sınırlamalar, geleneksel enerji kaynaklarının yarattığı zorlukların üstesinden gelmek ve küresel artan enerji talebini karşılamak için daha verimli MPPT kontrolörleri, yeterli gelişmiş güç elektroniği kontrol teknikleri, pil yönetim sistemleri ve saha seçiminin dikkatli bir şekilde planlanmasıyla çözülebilir (Zeb et al., 2018).




Şekil 1.2. 2001-2023 yılları arasında küresel PV enerji kurulumu

Yarı iletken malzemeler, paketlenme ve maliyet düşürme alanlarındaki ilerlemeler sayesinde solar enerjili PV'ler RES'ler arasında en hızlı büyümeyi yaşamıştır (Apeh et al., 2022). Ayrıca, PV panelinin hareketli parçası yoktur, bu da onu uzun ömürlü, sağlam ve az bakım gerektiren bir cihaz haline getirir. Bu yüzyılın sonunda, toplam enerjinin %60'ına varan oranlarda RES'ler arasında en önemli üretime sahip olması beklenmektedir (Islam et al., 2015). Son yıllarda, Şekil 1.2'de gösterildiği gibi, dünya çapında bir PV sisteminin kurulu kapasitesi keskin bir şekilde artmıştır (Makkiabadi et al., 2021), (Javadi et al., 2020). Yirminci yüzyılın sonlarında ABD, 1996 yılında yaklaşık 77 MW'a ulaşan solar PV kurulumunun zirvesindeydi (Edenhofer et al., 2012). Japonya 2004 yılında ABD'yi geçerek 1132 MW'lık bir solar PV üretim kapasitesine ulaşmıştır. Almanya, takip



eden on yıl boyunca dünyanın en büyük solar PV'si ile üretilen elektrik üreticisi oldu ve 2016 yılında yaklaşık 40 GW elektrik üretti. Çin, 2017 yılında Almanya'yı geride bırakarak sadece PV sistemlerinden 100 GW elektrik üreten ilk ülke olarak dünyayı şok etti (Edenhofer et al., 2011). 2018 sonu itibarıyla dünya çapında 500 GW'tan fazla PV sistemi kurulmuştur.

Bir solar PV sisteminin temel parçaları **Şekil 1.3**'te gösterildiği gibi (a) PV hücresi, (b) PV modülü veya paneli ve (c) PV dizisidir. Bir solar PV hücresi, fotovoltaiik etkiyi kullanarak solar ışığını doğru akım (DC) elektriğe dönüştüren bir solar PV sisteminin en küçük yapı taşıdır. Bir PV modülü veya paneli, belirli bir miktarda güç üretmek için seri ve paralel olarak bağlanmış birkaç PV hücresi içerir. (c) Bir PV dizisi, bağımsız veya şebekeye bağlı bir PV sistemi için istenen çıkış gücünü elde etmek üzere seri ve/veya paralel kombinasyonlarda bağlanmış birkaç PV modülünden veya panelinden oluşur (J. Sadhukhan, 2018).




**Şekil 1.3.** Bir PV hücresinin, PV modülünün ve PV dizisinin gösterimi

Solar PV sistemlerinin iki çalışma modu vardır: (a) bağımsız çalışma ve (b) şebekeye bağlı mod. Bağımsız çalışmada, solar PV panelleri tarafından üretilen güç DC yüklere güç sağlamak için bir batarya bankasında depolanır ve konut AC yüklerine güç sağlamak için bir DC-AC inverteri kullanılır. Şebekeye bağlı çalışmada, PV panelin çıkış gücü bir DC-AC inverter kullanılarak AC'ye dönüştürülür ve ardından aktif ve/veya reaktif güç şebekeye aktarılır (Kaundinya et al., 2009).

Şebeke bağlantılı PV sistemler ayrıca tek aşamalı ve iki aşamalı PV sistemler olarak sınıflandırılır. Tek kademedede, PV gücü şebeke ile güç alışverişi için doğrudan DC-

AC çeviriciye verilir. İki aşamalı dönüştürücüde, PV çıkışı DC-DC dönüştürücüye verilir ve Maksimum Güç Noktası İzleme (MPPT) kontrol teknikleri dönüştürücünün anahtarını kontrol eder (Chouhan et al., s2021). DC-DC dönüştürücünün çıkışı, DC bara veya DC bağlantı gerilimi olarak da adlandırılır, şebeke entegrasyonu için DC-AC invertere beslenir.



Şekil 1.4. Önerilen 100 kW şebekeye bağlı PV sisteminin tek hat şeması

Bu tezde, önerilen araştırma iki aşamalı 100 kW şebeke bağlantılı bir solar PV sistemine dayanmaktadır. İlk aşamada, yükseltici tip DC-DC dönüştürücü solar PV DC voltajını artırır ve LSTM tabanlı bir MPPT kontrolörü tarafından kontrol edilir. İkinci aşamada, aynı zamanda DC bağlantı gerilimi olan DC yükseltilmiş gerilim, üç fazlı üç seviyeli bir NPC inverter kullanılarak AC'ye dönüştürülür ve aktif ve doğrultucu güç aktarımı ve kontrolü Şekil 1.4'te gösterildiği gibi bir droop denetleyici kullanılarak gerçekleştirilir.

## 1.2. Araştırma Motivasyonu

Mevcut ticari solar panellerinin verimliliği çok düşüktür ve hava parametrelerinin kesintili olması nedeniyle %10-25 aralığında kalmaktadır (Hassan et al., 2022). Buna ek olarak, T ve G'deki hızlı dalgalanmalar solar panellerinin çıkış akımı ve voltajı üzerinde önemli bir etkiye sahiptir ve şebekeye bağlı PV sistemleri için (a) düşük hücre verimliliği, (b) güç kaybı, (c) DC bağlantı veya DC bara voltajında dalgalanma, (d) şebekeye enjekte edilen gücün düşük kalitesi ve (e) şebeke senkronizasyonu gibi çeşitli zorluklara yol açar. İlgili zorlukların bir açıklaması aşağıda vurgulanmıştır:

- Güneş pillerinin çıkış gücü üretimi,  $G$  ile doğru orantılı ve  $T$  seviyesi ile ters orantılıdır, bu nedenle hava parametrelerindeki hızlı değişim PV sistemini maksimum kapasitesinin altında çalıştıracak, güç kaybına neden olacak ve verimliliğini azaltacaktır (Anani & Ibrahim, 2020).
- Çift kademeli şebeke bağlantılı PV sistemlerde, DC-DC dönüştürücü aracılığıyla PV panelin çıkışına ve DC-DC inverterin girişine doğrudan bağlı olan DC bağlantı voltajının kararlılığı, PV sistemin verimliliğini artırmak için önemli bir rol oynar. Hava durumu parametrelerinin aralıklı olması DC bağlantı gerilimini nominal değerinden saptırır, böylece DC-AC eviricinin giriş tarafındaki kararsızlık eviricinin ve genel olarak şebekeye bağlı PV sistemin verimliliğini azaltır (Krishnamurthy et al., 2019).
- Hem bağımsız hem de şebekeye bağlı PV sistemlerde, DC-DC dönüştürücünün veya DC-AC İnverterin güç elektroniği bileşenlerinin elektronik devresi harmonikleri ortaya çıkarır ve PV sistemin verimliliği için bir zorluk teşkil eder. Bu nedenle, sistemin verimliliğini artırmak için endüktif ve kapasitif bileşenlerin tasarımı da gereklidir.
- Şebeke bağlantılı çalışmada, PV panelin çıkış gücü bir DC-AC İnverter kullanılarak AC'ye dönüştürülür ve ardından solar paneli ile bağlı şebeke arasında aktif ve/veya reaktif güç alışverişi yapılır. İletilen akım ve gücün harmonik azaltımı da verimliliği artırmak için çok önemlidir.

Yukarıda bahsedilen zorluklarla başa çıkmak için MPPT algoritmaları, çalışma koşullarını mevcut hava koşullarına uyacak şekilde sürekli olarak ayarlayarak bir solar panelinin güç çıkışını optimize etmek için iyi bir seçimdir. Bu nedenle, yükseltici tip DC-DC dönüştürücü tarafından takip edilen MPPT kontrol teknikleri, çalışma koşullarını mevcut hava koşullarına uyacak şekilde sürekli olarak ayarlayarak PV panelinin çıkış gücünü en üst düzeye çıkarır ve solar panelinin maksimum kapasitede çalışmasına yardımcı olur. Genel PV sisteminin verimliliğiyle ilgili yukarıda bahsedilen sorunlara ek olarak, MPPT'nin kendi verimliliği de şebekeye bağlı solar PV sisteminde önemli bir sorundur. Son teknoloji ürünü çalışmalarda, araştırmacılar bir PV sisteminin verimliliğini artırmak için çeşitli MPPT algoritmaları sunmuşlardır ve bunlar Bölüm 2'deki literatür taramasında kısaca açıklanmıştır. Makine Öğrenimi (ML) ve Derin Öğrenmenin (DL) ortaya çıkışı, solar PV sistemlerinin verimliliğini ve performansını önemli ölçüde artırma potansiyeline sahiptir (Forootan et al., 2022) ve bu alandaki araştırmalar, önerilen

çalışmanın ana motivasyonu olan yeni yöntemler ve algoritmalar geliştirmek için devam etmektedir.

### 1.3. Araştırma Hedefleri

Önerilen araştırmanın amacı, geleneksel enerji kaynaklarının sınırlamalarını, temiz, ekonomik ve bol miktarda bulunan bir RES olan solar PV enerjisini entegre ederken ortaya çıkan zorlukları ele almak ve bütünsel LSTM tabanlı MPPT kontrol algoritmasını uygulayarak şebekeye bağlı PV sistemlerinin verimliliğini artırmaktır. Amaç, daha iyi performans için sistemin karmaşıklığını azaltırken MPPT algoritmasının doğruluğunu ve verimliliğini artırmaktır. Son teknoloji MPPT kontrolörlerinin aksine, LSTM tabanlı MPPT kontrolörleri geçmiş bilgileri depolayan hafıza hücrelerine sahiptir, bu da değişen koşullara daha iyi adapte olmalarını sağlar ve hava koşullarındaki hızlı değişikliklere rağmen MPPT algoritmasının doğruluğunu artırır (K. Wang et al., 2019). Ayrıca, LSTM tabanlı MPPT kontrolörleri G, T, gerilim ve akım gibi zaman serisi verilerinin zamansal bağımlılıklarını dikkate alır. Bu, değişen koşullara daha iyi adapte olmalarını sağlar ve MPPT algoritmasının doğruluğunu artırır. LSTM tabanlı MPPT, PV hücresinin doğrusal olmayan yapısını ve dinamiklerini yönetebilir ve bu da daha iyi performans sağlar. Ek olarak, LSTM tabanlı MPPT kontrolörlerinin bellek hücreleri, MPPT takibi sırasında kısmi gölgelenme ve çoklu maksimum güç noktalarının ele alınmasına izin verir, bu da daha iyi performans sağlar (Gers et al., n.d.). Genel olarak, LSTM'nin zaman serisi verilerini, nonlineerliği, dinamikleri ve bellek hücrelerini işleme yeteneği, geleneksel MPPT denetleyicilerinden daha iyi performansla yol açar (Pengcheng & Jiawei, 2021). Ana hedef noktaları aşağıda vurgulanmıştır:

- LSTM ağları, T, G, voltaj ve akım dahil olmak üzere PV sistemlerinden gelen zaman serisi verilerinin karmaşıklığını ve dinamiklerini idare edebilir. Ayrıca, bir bellek bileşeninin varlığı, veriler arasında bağımlılıklar oluşturmak için uygun hale getirir ve FFNN'ye kıyasla üstün performans sağlar. Bununla birlikte, LSTM'nin uzun süreli eğitimi performansını yavaşlatabilir. Bu nedenle, bu araştırmanın amacı, büyük zaman serisi verileri için verimli bir LSTM tabanlı MPPT geliştirmek ve daha iyi performans elde etmek için daha az gizli birimle karmaşıklığını azaltmaktır.
- Önerilen çalışma, düşük MPP'ye sahip daha az sayıda PV panel ile daha yüksek güç seviyesi elde etmek ve aynı zamanda DC bağlantı voltajını düzenlemek için

MPPT ile DC-DC yükseltici tip DC-DC dönüştürücü kullanan çift aşamalı şebekeye bağlı bir PV entegrasyonu sunmaktadır. Bu yaklaşım, PV sisteminin çevresel koşullardaki değişikliklerden bağımsız olarak optimum noktada çalışmasına izin verecek ve bu da genel sistemin daha iyi performans göstermesine yol açacaktır.

- DC bağlantı voltajı, PV dizisinin eviriciye bağlandığı voltaj seviyesidir ve PV dizisi tarafından üretilen DC gücünü şebekeye beslenebilecek AC gücüne dönüştürür. DC bağlantı voltajı regüle edilmezse, eviricinin optimum aralığının dışında çalışmasına neden olarak verimliliğin ve performansın düşmesine neden olabilir (Meraï et al., 2021). Ayrıca, DC bağlantı voltajı çok yüksek veya çok düşükse, eviriciye ve sistemin diğer bileşenlerine zarar verebilir. DC bağlantı voltajını bir referans değerinde düzenleyerek, sistem istikrarlı ve tutarlı bir güç çıkışı sağlayabilir ve ekipmanın uzun ömürlü olmasını sağlayabilir.
- LSTM'nin büyük veri eğitimi ve hesaplama yükü, önerilen çift aşamalı şebekeye bağlı PV sisteminin karmaşıklığını artırmaktadır. Bu nedenle, önerilen çalışma inverter kontrol karmaşıklığını azaltmaya odaklanmıştır. İlk aşamada, LSTM ağında daha az gizli birim kullanılarak karmaşıklık azaltılır. İkinci aşamada, önerilen sistemin verimliliğinden ödün vermeden modelin basitliğini sağlamak için akım ve gerilim kontrol döngüsünde basit PI kontrolörü kullanılır.

#### 1.4. Araştırma Katkıları

Önerilen çalışmada, Simulink/MATLAB 2023® kullanılarak 100 kW üç fazlı çift kademeli 100 kW şebeke bağlantılı bir PV sistem modellenmiştir. Model iki aşamaya ayrılmıştır; (a) şebekeye bağlı PV sisteminin birinci aşaması ve (b) ikinci aşaması. İlk aşama solar PV dizisi, yükseltici tip DC-DC dönüştürücü ve MPPT kontrolöründen oluşmaktadır. İkinci aşama DC bağlantı gerilim kontrolü ve inverter kontrolünden oluşmaktadır. İnverter kontrol tasarımıdaki voltaj kontrol döngüsü ve akım kontrol döngüsü, şebekeye saf AC gücü enjekte etmek için DC bağlantı voltajını korur. Tezin ana katkıları aşağıda listelenmiştir:


- İlk aşamada, modül başına toplam 96 hücre, dizi başına 5 seri bağlı modül ve 100 kW maksimum güç elde etmek için 65 paralel diziden oluşan SunPower TS-SPR-315E PV paneli dikkate alınmıştır:  $P_{pv} = P_{max} * N_p * N_s = 315 * 65 * 5 = 102 \text{ kW}$ .

- Hızlı hava değişimlerinin varlığında iki aşamalı şebekeye bağlı bir solar PV sistemi için bütünsel bir LSTM tabanlı MPPT algoritmasının tasarımı, modellenmesi ve simülasyonu gerçekleştirilmiştir. T ve G iki zaman serisi dizisi girdisidir ve MPP'deki PV voltajı önerilen LSTM ağının hedefi veya çıktısıdır. LSTM tarafından verilen çıkış gerilimleri ve gerçek PV gerilimi, sinüzoidal PWM modülasyonu için referans gerilim sinyalinin çıkararak ve yükseltici tip DC-DC dönüştürücünün anahtarını kontrol etmek için görev döngüsünü üreten PI kontrolüne verilir.
- DC giriş voltajının seviyesini 250-280 V'tan 800 V DC'ye çıkararak önemli bir rol oynayan, ani yük değişimi sırasında sistemi koruyan, şebeke gücünün uyumluluğunu ve kalitesini sağlamak için daha düşük MPP ile yüksek çıkış gücü elde etmeye yardımcı olan DC-DC yükseltici tip DC-DC dönüştürücünün tasarımı ve simülasyonu gerçekleştirilmiştir.
- İkinci aşamada, yükseltici tip DC-DC dönüştürücünün çıkışı olan DC link veya DC bara voltaj kontrolü, ilk aşamadaki LSTM MPPT kontrolörü ve voltaj ve akım kontrolörleri için ilgili PI kontrolörü düzenlenmiştir.
- Son olarak, DC-AC inverterin kararlı girişi, daha az harmonik içeren kararlı AC çıkışı üretir. PV paneli entegre şebekeye aktif akım (reaktif akım sıfır olarak kabul edilir) ve aktif güç enjekte eder.

Önerilen LSTM MPPT kontrolörünün eğitimi ve testi MSE, RMSE, MAE, R2 ve kayıp fonksiyonu gibi performans indeksi parametreleri kullanılarak sağlanmıştır. Test edilen model daha sonra Simulink MATLAB'a aktarılmış ve şebekeye bağlı PV Simulink modeli ile entegre edilmiştir. Önerilen LSTM modelinin daha yüksek verimliliği, son teknoloji MPPT algoritmalarıyla karşılaştırılarak sağlanmıştır. Karşılaştırmalı analizin kolaylığı için, önerilen LSTM, aynı katman sayısına ve aynı gizli katman sayısına sahip ileri beslemeli Derin Sinir Ağı ile karşılaştırılmıştır.

### 1.5. Tez Organizasyonu

**Şekil 1.5** tezin yapısını göstermekte, 1 ila 6. bölümlerin kilit noktalarını özetlemekte ve her bölümün konularına ve katkılarına kısa ama kapsamlı bir genel bakış sağlamaktadır. Bu görsel temsil, tezin yapısının ve temel bulgularının kavranmasına yardımcı olmak için hızlı bir referans işlevi görmektedir. Tezin geri kalanı aşağıdaki şekilde düzenlenmiştir:



Şekil 1.5. Tüm bölümlerin ana temalarını ve katkılarını vurgulayarak tez organizasyonuna genel bakış

- **Bölüm 1'de (Giriş)**, geleneksel enerji kaynaklarının eksiklikleri, yenilenebilir enerji kaynaklarına duyulan ihtiyaç ve önerilen iki aşamalı PV sisteminin ilk aşamasında LSTM tabanlı MPPT denetleyicisinin ve ikinci aşamasında evirici kontrol tasarımının öneminden oluşan araştırma arka planının kısa bir açıklaması verilmiştir. Araştırma arka planını, bu tezde önerilen çalışmanın motivasyonu, hedefleri ve katkıları takip etmektedir. Son olarak, her bölümün kısa bir özeti tezin organizasyonunu vurgulamaktadır.
- **Bölüm 2'de (Literatür Taraması)**, şebekeye bağlı solar PV sistemlerinin iki aşamasına ilişkin kapsamlı bir literatür taraması açıklanmaktadır. İlk olarak, güç üretim aşaması için geleneksel, akıllı, hibrit ve AI/ML/DL tabanlı MPPT teknikleri gözden geçirilmiştir. Önceki MPPT çalışmalarından elde edilen temel bulgular, yaklaşımlar, sınırlamalar ve boşluklar analiz edilmektedir. Bölüm daha sonra ikinci aşama şebeke entegrasyon topolojileri ve kontrol stratejileri üzerine önceki çalışmaları gözden geçirmektedir. Son olarak, mevcut yöntemlerle ilgili kalan zorluklar vurgulanmakta ve önerilen LSTM tabanlı MPPT kontrolörünün kapsamı belirlenmektedir. Dolayısıyla, bu bölüm literatür hakkında kapsamlı bilgi sağlamakta, açık araştırma boşluklarını belirlemekte ve solar PV teknolojisinin

optimize edilmiş şebeke entegrasyonu için yapay zekâ tabanlı kontrolü ilerletmek üzere mevcut çalışmayı konumlandırmaktadır.

- **Bölüm 3 (Materyaller ve Yöntemler)**, tez araştırmasının odak noktası olan iki aşamalı şebekeye bağlı PV sistemini açıklamaktadır. Panel özellikleri, voltaj yükseltme için yükseltici tip DC-DC dönüştürücü tasarımı ve güneş enerjisi çıkarımını optimize etmek için bir maksimum güç noktası izleme kontrolörü dahil olmak üzere PV panellerden güç üretmenin ilk aşamasını detaylandırarak başlar. Bölüm daha sonra, şebekeye bağlı inverterler hakkında arka plan sağlayarak, çeşitli inverter topolojilerini ve mimarilerini gözden geçirerek, inverter kontrol yöntemlerini açıklayarak ve PV inverter sistemi için önerilen kademeli kontrol yaklaşımını ve LCL filtre tasarımını açıklayarak PV sistemini şebekeye entegre etmenin ikinci aşamasını kapsamaktadır. Bu metodoloji bölümünde sunulan detaylar, ilerleyen bölümlerde tartışılacak olan sistem uygulaması, deneyler ve sonuçlar için temel oluşturmaktadır.
- **Bölüm 4 (Önerilen Araştırma Metodolojisi)**'inde şebekeye bağlı PV sisteminde MPPT kontrolü için önerilen stack LSTM ağ metodolojisi sunulmaktadır. LSTM ağ mimarisi, aktivasyon fonksiyonları, hiperparametreler ve bunların türleri sunulmuştur. Önerilen stack LSTM ağının geleneksel MPPT yaklaşımlarına kıyasla gelişmiş performans, uzun vadeli bağımlılık modellemesi, hiyerarşik temsil ve esneklik sunduğu açıklanmaktadır. Bölümde daha sonra stack LSTM'nin genel bir iki aşamalı PV sisteminde MPPT kontrolörü olarak nasıl uygulandığı açıklanmaktadır. Veri toplama, ön işleme, ağ yapılandırması, eğitim ve test ile ilgili ayrıntılar verilmektedir. MSE, RMSE, MAE, R2 ve doğrulama kaybı gibi performans değerlendirme metrikleri seçilmiştir. Son olarak, PV sistemde DC'den AC'ye dönüşüm için kullanılan 3 fazlı 3 seviyeli NPC İnverter topolojisi incelenmiştir. Bu şekilde DC bağlantı gerilimi düzenlenir ve aktif güç PV dizisinden elektrik şebekesine aktarılır.
- **Bölüm 5 (Sonuçlar ve Tartışma)**, şebekeye bağlı PV sistemlerinin MPPT kontrolü için stack bir LSTM ağının uygulanması sırasında elde edilen sonuçları ve tartışmayı sunmaktadır. Bölüm, LSTM ağını eğitmek ve test etmek için kullanılan giriş verilerinin elde edilmesi, ön işlemiden geçirilmesi ve normalleştirilmesinin ayrıntılı bir açıklaması ile başlamaktadır. Bunu, verilerin görselleştirilmesi takip etmektedir. LSTM ve DNN-MPPT modellerinin eğitim süreci ve performans değerlendirmesi, LSTM'nin DNN ve geleneksel P&O



algoritmalarından daha yüksek doğruluk göstermesiyle analiz edilir. Eğitilen LSTM, tüm PV sisteminin gerçek zamanlı MPPT kontrolü için kullanılır ve sonuçlar etkili MPP çıkarımı gösterir. Üç seviyeli NPC inverterin çıkış gerilimi, şebeke bağlantısı ve güç enjeksiyonu sonuçları kararlı çalışma göstermektedir. Simülasyon sonuçları, istiflenmiş LSTM'nin FF-DNN ve P&O dahil olmak üzere diğer MPPT yöntemlerinden önemli ölçüde daha iyi performans gösterdiğini doğrulamaktadır.

- **Bölüm 6 (Sonuçlar ve Öneriler)** tezin ana araştırma sonuçlarını ve kazanımlarını özetlemektedir. Şebekeye bağlı güneş enerjisi sistemlerinin MPPT kontrolü için stack LSTM ağının geliştirilmesi ve uygulanmasıyla elde edilen ana bulgulara ve katkılara kısa bir genel bakış sunmaktadır. Bölüm daha sonra araştırmanın önemini ve potansiyel etkisini vurgulayarak sona ermektedir. Son olarak, mevcut araştırmanın sonuçlarına dayanarak keşfedilecek olası uzantılar, iyileştirmeler ve açık sorular da dahil olmak üzere gelecekteki çalışmalar için öneriler sunulmaktadır. Genel olarak, bu sonuç bölümü tez sonuçlarını özetlemekte, araştırma değerini vurgulamakta ve yenilenebilir enerji sistemlerinde yapay zeka tabanlı kontrol tekniklerini ilerletmek için yeni yönlerle işaret etmektedir.

## 2. KAYNAK ARAŞTIRMASI

Fotovoltaik (PV), çevre dostu olan ve artan enerji talebinin karşılanmasında önemli bir rol oynayan temiz, bol miktarda bulunan yenilenebilir bir kaynaktır. PV sistemlerinin elektrik şebekesine entegrasyonu, fosil yakıtlara olan bağımlılığı azaltmak ve iklim değişikliğiyle mücadele etmek için kritik öneme sahiptir. PV enerjinin çeşitli faydalarına rağmen, entegrasyonu, değişken hava koşullarında güç çıkarımını optimize etmek, PV tarafından üretilen enerjideki DC voltaj dalgalanmalarını yönetmek, DC-AC dönüşümündeki harmoniklerle başa çıkmak ve güç faktörü düzeltmesi yoluyla şebekeye istikrarlı ve senkronize güç enjeksiyonu sağlamak gibi çeşitli zorluklarla birlikte gelir (Mahlooji et al., 2018). Güneş enerjisi sistemlerindeki benzer şebeke entegrasyon zorlukları, tek aşamalı ve iki aşamalı yaklaşımlar karşılaştırılarak yazarlar tarafından (Chouhan et al., 2021)'de ele alınmıştır. İki aşamalı strateji, bir yükseltici tip DC-DC dönüştürücü aracılığıyla DC gücünü optimize eder ve ardından şebeke entegrasyonu için bir inverter kullanarak AC gücüne dönüştürür. İki aşamalı sistemler, MPPT, akım limitlerini azaltan voltaj yükseltme dönüşümü, DC bağlantı voltajı kararlılığı, inverter çalışması ve özel bileşenler nedeniyle güç enjeksiyonu açısından tek aşamalı benzerlerinden daha iyi performans gösterir. Ayrıca, Işınım (G) ve Sıcaklık (T) gibi değişken hava parametrelerinin varlığında bile daha yüksek verimlilik ve kararlılık sunar. İlk aşama PV dizisi, yükseltici tip DC-DC dönüştürücü ve MPPT kontrolörünü içerirken, ikinci aşama sorunsuz AC güç üretimi için inverter, PLL ve LCL filtresini içerir.

**Bölüm 2** (literatür taraması), iki aşamalı şebekeye bağlı PV sistemdeki geçmiş gelişmeleri ve ilgili zorlukları araştırmaktadır. İlk aşama PV panelleri, yükseltici tip DC-DC dönüştürücü, MPPT kontrolörü ve inverter kontrolörünü içerir. İkinci aşama DC-AC dönüştürücü, PLL ve LCL filtresini içermektedir. Ayrıca geleneksel, akıllı ve derin öğrenme (DL) tabanlı MPPT yöntemleri de dahil olmak üzere en son MPPT yöntemlerini eleştirel bir şekilde incelemektedir. Bölüm 3'te tüm bileşenlerin modellenmesi ve tasarımı sunulmaktadır. Belirlenen zorlukların üstesinden gelmek için, Bölüm 3'te optimize edilmiş PV üretiminin doğruluğunu ve verimliliğini artırmak için yeni bir stack LSTM-MPPT kontrolörü sunulmuştur. Model, DC bağlantı voltajını korumak için bir LSTM-MPPT kontrolörü ve bir boost mekanizması, invertere giden güç çıkışını stabilize etmek için bir PI kontrolörü ve kritik sorunları çözmek ve genel verimliliği ve kararlılığı artırmak için diğer bileşenleri entegre eder. Bu bölümde, literatür taraması iki aşamada devam etmektedir- ilk olarak, şebekeye bağlı PV sistemlerde kullanılan farklı MPPT

stratejileri üzerine literatür taraması ve ardından evirici kontrol topolojileri üzerine literatür taraması.

## 2.1. Şebekeye Bağlı PV'nin İlk Aşamasına İlişkin Literatür Taraması

Bu bölüm, şebekeye bağlı solar PV sistemlerinin ilk aşaması hakkında kapsamlı bir literatür taraması yapmaktadır. Amaç hem geleneksel yaklaşımları hem de akıllı ve yapay zekâ tabanlı MPPT kontrol sistemlerini kullanan solar PV alanındaki son gelişmeleri göz önünde bulundurarak MPPT teknolojisinin önceki ve mevcut durumunu değerlendirmektir. Bu literatür taramasının amacı, mevcut bilgileri vurgulamak, eksikliklere işaret etmek ve bu yaklaşımların ortaya çıkardığı zorlukları tartışmaktır. Bu, önerilen araştırma yöntemimiz olan istiflenmiş LSTM MPPT kontrolörü için önemli bir temel sağlar. Bu yeni yaklaşım, şebekeye bağlı solar PV sistemlerinin ilk aşamasının doğruluğunu ve verimliliğini artırmayı amaçlamaktadır. Bu bölüm ayrıca aşağıda listelenen beş alt bölüme ayrılmıştır:

- Geleneksel MPPT Yöntemlerinin Geçmiş Araştırmaları
- Akıllı MPPT Yöntemleri Üzerine Literatür Taraması
- Hibrit MPPT Yöntemleri Üzerine Literatür Taraması
- AI, ML veya DL tabanlı MPPT Yöntemlerinde Tarihsel Gelişim
- Son Teknoloji MPPT Yöntemleriyle İlgili Potansiyel Zorluklar
- Önerilen Stack LSTM MPPT Yöntemleri

### 2.1.1. Geleneksel MPPT Yöntemlerine İlişkin Literatür Taraması

FSCC (Kesirli Kısa Devre Akımı), Pertürbasyon ve Gözlem (P&O), Artımlı İletkenlik (IC), Tepe Tırmanışı (HC), Açık Devre Gerilimi (OCV) ve Kısa Devre Akımı (SCC) yöntemleri dahil olmak üzere PV sistemleri için geleneksel MPPT teknikleri ekonomik ve basittir. MPP'yi gerilim ve akım değişimlerini izleyerek (P&O ve IC), çıkış gerilimini kademeli olarak değiştirerek (HC) veya açık devre gerilimini ve kısa devre akımını inceleyerek (OCV ve SCC) belirlerler. Ancak bu yöntemler, yavaş yakınsama ve gürültüye duyarlılık nedeniyle büyük ölçekli şebeke bağlantılı sistemlerde zorluklarla karşılaşmaktadır. Aşağıda bu algoritmalarla ilgili bir literatür taraması yer almaktadır.

(Das, 2016)'daki yazarlar, düşük maliyetli bir PIC mikroişlemci kullanarak FOCV tabanlı şebekeden bağımsız PV sistemleri için bir MPPT kontrolörü sunmuşlardır. Bu yaklaşım yalnızca düşük güçlü şebekeden bağımsız PV sistemleri için iyi çalışmaktadır, ancak, ani hava değişiklikleri sırasında MPP etrafındaki salınımlardan ve dalgalanmalardan etkilenecektir. Bu nedenle, şebekeye bağlı solar PV sistemleri için daha gelişmiş MPPT kontrolörlerine ihtiyaç vardır.

(Sher et al., 2015)'deki yazarlar şebekeden bağımsız PV sistemlerin MPPT'si için çevrimdışı kesirli kısa devre akımı (FSCC) yöntemini önermişlerdir. FSCC, optimize edilmiş kısa devre akımı ölçüm zamanlaması sayesinde modelleme etkinliğini artırmaktadır. Bununla birlikte, örnekleme sırasında güç kaybı yaşar ve P&O ve IC gibi gelişmiş çevrimiçi tekniklerin yanı sıra değişen koşullara hızla yanıt veremez.

(Bahari et al., 2016), verimliliği daha da artırmak için iki indüktörlü benzersiz bir Tek Uçlu Birincil İndüktör Dönüştürücü (SEPIC) ve bir anahtar kullanan bir HC MPPT teknolojisi sunmuştur. HC teknolojisi küçük PV sistemleri için basit ve ekonomik olsa da orta ve büyük ölçekli şebekeye bağlı PV sistemleri için gelişmiş MPPT kontrolörleri gereklidir. Bunun nedeni HC MPPT'nin MPP etrafında salınım yapma eğiliminde olması ve hızla değişen hava koşullarında kötü performans göstermesidir.

Yazarlar, (John et al., 2018)'de hızlı yanıt ve düşük hesaplama karmaşıklığını göz önünde bulundurarak, bağımsız PV sistemi için değişken adım boyutlu bir P&O MPPT algoritması önermişlerdir. Bu yöntem, MPP'den uzaklığa göre pertürbasyon adım boyutlarını değiştirerek izleme verimliliğini ve doğruluğunu artırmayı amaçlamaktadır. Gelişmiş IC yöntemi çeşitli senaryolar altında gelişmiş performans gösterse de, P&O daha basit ve daha az karmaşıktır çünkü tipik olarak yalnızca voltaj (V) sensörlerini kullanırken, IC MPPT daha karmaşık bir kontrol algoritması için hem voltaj hem de akım sensörlerini kullanır.

Doğruluğu daha da artırmak için, bağımsız solar PV sistemleri için geliştirilmiş bir IC MPPT yaklaşımı araştırmacılar tarafından (Huynh & Dunnigan, 2016)'da sunulmuştur. Değiştirilmiş IC yöntemi, basitleştirilmiş hesaplamaları ve sınırlı arama bölgesi nedeniyle daha hızlı ve daha yüksek doğrulukla yakınsamıştır. Bu değiştirilmiş IC, temel IC ve P&O yaklaşımlarından daha karmaşık olmasına rağmen, daha iyi performans göstermiş ve şebekeye bağlı PV sistemleri için gelişmiş MPPT algoritmalarının kullanılmasını önermiştir. P&O yöntemi gibi, IC yöntemi de ısıtım ve sıcaklık hızla değiştiğinde MPP etrafında salınır.

Geleneksel MPPT yöntemlerinin basit, daha az karmaşık ve hızlı olduğu, ancak hava koşullarındaki hızlı değişiklikler altında orta veya büyük ölçekli şebekeye bağlı PV sistemleri için iyi performans göstermediği açıktır (Podder et al., 2019). Bu nedenle, bir sonraki alt bölümde açıklanan daha gelişmiş MPPT yöntemleri, büyük ölçekli şebekeye bağlı PV sistemler için gereklidir.

### 2.1.2. Akıllı MPPT Yöntemlerine İlişkin Literatür Taraması

Geleneksel MPPT yöntemleri solar PV sistemleri için basit ve uygun maliyetli olmasına rağmen, bu yöntemler yakınsama gecikmelerine ve çevresel değişikliklere duyarlılığa eğilimlidir. Bu zorluklar nedeniyle, sistem performansını uyarlamak ve iyileştirmek için FLC, SMC, PSO, GA ve ANN gibi son teknoloji algoritmaları kullanan akıllı MPPT yöntemlerinin entegre edilmesi gerekmektedir. Yumuşak hesaplama kullanan bu akıllı yöntemler, geleneksel yöntemlerin dezavantajlarının üstesinden gelir ve MPP takibinin verimliliğini ve doğruluğunu artırır. Bu nedenle, literatürdeki bir dizi akıllı MPPT yöntemi bu alt bölümde sunulmuştur.

(Ansari et al., 2013)'de yazarları ayrı bir DC-DC dönüştürücüsü olmayan üç fazlı şebekeye bağlı bir PV sistemi için bir FLC-MPPT algoritması uygulamıştır. FLC tabanlı MPPT algoritmaları, güvenilir olması gereken daha büyük sistemler için uygundur, ancak kontrol kuralları geliştirmek için uzman bilgisi gerektirir. Karmaşık doğrusal olmayan etkileşimlerle başa çıkmada Yapay Sinir Ağı (ANN) yaklaşımları kadar akıllı değildir. MPPT'nin yanı sıra, FLC elektrik motorlarının kontrolünde de kullanılmaktadır. (Tarbosh et al., 2020)'deki yazarlar, motor sürücülerinde FLC uygulamalarını tartışan bir makale yayınlamışlardır. Benzer şekilde, (Anwer et al., 2020)'deki yazarlar, sensörsüz hız kontrollü bir PV sistemi ile çalışan bir sabit mıknatıslı senkron motor (PMSM) sürücüsü tasarlamak için Simulink'i kullanmışlardır. FLC tabanlı bir MPPT algoritması ve Model Referans Adaptif Sistem (MRAS) yaklaşımını kullanan sensörsüz hız tahmin edicili bir PMSM sürücüsü kullanmışlardır. Geleneksel kontrolörlerin aksine, FLC kural tasarımı karmaşık bir görevdir ve daha yüksek doğruluk için özel uzman bilgisi gerektirir.

(Ishaque et al., 2012)'de, bağımsız fotovoltaik sistemler için tipik tepe tırmanma yönteminin yerine geliştirilmiş bir PSO tabanlı MPPT önerilmiştir. Parçacıkların hızına ve konumuna bağlı olarak, PSO algoritması MPP'yi izlemek için dönüştürücünün görev döngüsünü değiştirir. Algoritma MATLAB/Simulink kullanılarak modellenmiş ve simüle edilmiştir. Daha sonra d-SPACE DS1104 teknolojisi kullanılarak programın bir prototipi

geliştirilmiştir. Sonuçlar, ışıınım değişimleri, yük artışı ve kısmi tıkanıklık altında hızlı izleme ve temel HC'ye kıyasla kararlı durum salınımlarının olmadığını göstermektedir. Yazarlar, geleneksel MPPT yöntemlerine kıyasla performansın iyileştirildiğini ve yöntemlerin küçük bağımsız PV sistemleri için önerildiğini belirtmektedir. Bu nedenle, karmaşık şebekeye bağlı PV sistemlerde girişler ve çıkışlar arasındaki doğrusal olmayan karmaşıklık izlemek için gelişmiş MPPT kontrolörleri önerilmektedir.

PV sistemleri için üç fazlı şebekeye bağlı inverter için akıllı SMC tabanlı MPPT kontrolü (Kim, 2007)'de tartışılmıştır. Bu yaklaşımda endüktör akımı, MPP'yi izlemek için MPPT tarafından üretilen referans değeri takip etmek üzere SMC tarafından yönetilir. Bu nedenle, ayrı bir DC-DC dönüştürücü gerekli değildir. Simülasyon ve donanım sonuçları MPPT'nin farklı ışıınım seviyelerinde hızlı ve doğru bir şekilde çalıştığını göstermektedir. Entegratörün yükseltme etkisi dikkate alınmamasına rağmen, tasarım karmaşıklığı geleneksel MPPT yöntemlerine kıyasla yüksektir. Bu yöntem, hızlı dinamik yanıtın kritik olduğu şebekeye bağlı PV sistemler için iyi bir izleme sağlar. Bununla birlikte, SMC geleneksel MPPT yöntemlerinden daha yüksek tasarım karmaşıklığına sahiptir ve veriler arasındaki doğrusal olmayan bağımlılıkları yakalayamaması nedeniyle ANN yönteminden daha az verimlidir.

PV panellerin güç çıkışını artırmak için, (Hadji et al., 2018) 'deki yazarlar PV sistemleri için GA tabanlı bir MPPT kontrolörü önermişlerdir. Bu kontrolör, PID kontrolörünün ayarlarını yapmaktadır. GA tabanlı MPPT kontrolörü, verimlilik ve izleme hızı açısından geleneksel MPPT yöntemlerinden daha iyi performans göstermektedir. Doğruluk, hız ve kısmi gölgelenmenin kritik olduğu solar PV sistemleri için GA tabanlı MPPT kontrolörleri iyi bir izleme performansı sağlar. Geleneksel MPPT kontrolörleriyle karşılaştırıldığında, GA MPPT'nin tasarımı daha karmaşıktır ancak daha hızlı ve daha doğrudur. Buna ek olarak, GA'nın doğruluğu ANN yöntemine göre nispeten daha düşüktür çünkü ANN'nin büyük miktarda veri kullanılarak eğitilmesi ve bu verilere dayanarak daha yüksek doğruluk sağlaması gerekir.

(Zhao et al., 2021)'de, şebekeye bağlı PV sistemler için akıllı bir MPC MPPT tekniği sunulmuştur. Teknik, doğrusal bir PV dizisini modellemek için model tanımlamayı kullanır. Spektral dalga boylarına dayalı olarak, MPC kontrolörü sıcaklığın etkisini tahmin eder ve DQ-koordinatı inverter akımının yönetimini yönlendirir. Gerilim vektörleri, akım hatalarını azaltmak için tahmin modeli tarafından optimize edilir. Şebekeye bağlı üç fazlı bir PV inverter için MATLAB/Simulink simülasyonları, MPC'nin geleneksel yöntemlere kıyasla MPPT izleme performansını iyileştirdiğini göstermektedir.

Bununla birlikte, MPC tabanlı MPPT, P&O veya rampa tırmanma gibi basit yöntemlerden daha karmaşık bir tasarım gerektirir. Bununla birlikte, gelişmiş yapay zekâ tabanlı kontrolörler, küresel MPP'yi (GMPP) tahmin etmek için voltaj, akım veya ısıtım verilerini izleyerek ve doğruluğu ve verimliliği artırmak için SMC tahminini geliştirerek bu yaklaşımı tamamlayabilir.

Geleneksel ve akıllı MPPT yöntemlerinin sınırlamaları vardır. Bunları ele almak için (Kulaksiz & Akkaya, 2012b)'deki yazarlar, asenkron motor sürücülü bir PV sisteminde MPPT için bir ANN modelini optimize etmek için bir GA kullanmışlardır. Yazarlar, motor hızı için V/f kontrolü ve 3 fazlı inverter çalışması için SV-PWM uygulamış ve simülasyonlar ve deneyler yoluyla doğrulamışlardır. Benzer şekilde, (Rai et al., 2011)'de şebekeden bağımsız PV'de kısmi gölgelenme altında doğru MPPT için hızlı bir ANN ve HC algoritmasını birleştirmiştir. ANN tabanlı yöntemler geleneksel tekniklere kıyasla esneklik gösterirken, ML ve DL modelleri daha fazla ölçeklenebilirlik ve otomasyon sunar. Bu modeller transfer öğrenme kullanır ve mimarilerini otomatik olarak uyarlayarak daha az eğitim verisi gerektirir.

Doğruluğu daha da artırmak için, bir sonraki alt bölümde geleneksel yöntemlerin ve akıllı yöntemlerin avantajlarını birleştiren ve daha iyi sonuçlar vaat eden hibrit bir MPPT algoritması analiz edilmektedir.

### 2.1.3. Hibrit MPPT Yöntemlerine İlişkin Literatür Taraması

Hibrit MPPT yöntemleri hem geleneksel hem de akıllı kontrolörlerin özelliklerini birleştirir. Akıllı MPPT'ler uyarlanabilirlik ve performans optimizasyonu sağlarken, geleneksel MPPT'ler basit ve güvenilirdir. Bu hibrit yaklaşım, bağımsız yaklaşımlardan daha üstündür çünkü her iki kontrolörün de en iyi özelliklerine sahiptir, uyarlanabilirlikle birlikte verimlilik ve güvenilirlik sağlar (Bollipo et al., 2021). Araştırmacılar, farklı G ve T koşulları altında MPP izlemenin doğruluğunu ve verimliliğini artırmak için bu eksiksiz çözümü tercih etmektedir.

(Allahabadi et al., 2022), bağımsız PV'de kısmi gölgeleme altında MPPT sınırlamalarını ele almak için bir ANN önermiştir. ANN, hızlı ve doğru izleme için HC ile birleşir. Avantajları arasında yerel gölgeleme ve doğrusal olmayan etkileşimlerin ele alınması yer almaktadır. Bununla birlikte, sınırlamalar arasında yüksek hesaplama talebi, büyük eğitim verisi ihtiyaçları ve sonuçta ortaya çıkan derin öğrenme modellerinden daha düşük doğruluk bulunmaktadır. Benzer şekilde, (Kulaksiz & Akkaya, 2012a)'deki

yazarlar, doğrudan bağlı bir endüksiyon motoru sürücüsüne sahip bağımsız bir PV sisteminde MPPT için GA-optimizeli bir ANN kullanmışlardır. Tasarım, ANN'ların gürültü reddetme özelliğinden yararlanarak bir DC-DC dönüştürücüye olan ihtiyacı ortadan kaldırmaktadır. MPPT'deki değişen adım boyutu, izleme hızı ile MPP etrafındaki salınımlar arasındaki dengeyi ele almaktadır. Bununla birlikte, DL algoritmaları karmaşık doğrusal olmayan durumlarla başa çıkmak, değişen ortamlara uyum sağlamak ve GA-optimize ANN algoritmasına kıyasla özellik öğrenmeyi otomatikleştirmek için uygun bir seçimdir.

(Bouaouaou et al., 2022)'de, beş seviyeli şebeke bağlantılı bir PV inverter sistemi için MPC ve ANN'dan oluşan hibrit bir teknik önerilmiştir. ANN tabanlı MPPT algoritması MPP'yi etkili bir şekilde izlerken, MPC algoritması DC bara voltajını kontrol eder ve inverteri şebekeye aktif ve reaktif güç enjekte etmeye yönlendirir. ANN, optimum gerilim/akım modellerine dayalı olarak GMPP komşularını hesaplar, HC algoritması ANN tahmininden başlayarak gerçek GMPP'yi izler. Bununla birlikte, MPC'nin sağlamlığını sınırlayan model bağımlılığı gibi bazı dezavantajları vardır ve varyans ağı uzun bir eğitim süresi gerektirir. Bu zorlukların üstesinden gelmek için, veri kümesinin boyutunu ve hesaplama kaynaklarını artırarak daha fazla ilerleme kaydedilmesi gerekmektedir.

(Kulaksiz, 2013)'deki yazarlar, PV hücrelerinin tek diyotlu bir modelinde anahtar parametreleri elde etmek, performansı artırmak ve sistem maliyetlerini azaltmak için uyarlanabilir nöro-bulanık çıkarım sistemleri (ANFIS'ler) kullandılar. Çeşitli PV modül tiplerinde gösterilen yöntem, akü şarj uygulamaları olan bir PV sisteminde doğru MPPT kontrolü uygulamak için etkili olduğunu kanıtlamaktadır. Bir solar PV sisteminin çıkış gücünü en üst düzeye çıkarmak için (Revathy et al., 2022)'deki yazarlar, hem öğrenme yeteneği hem de basit bir tasarım sağlamak için ANFIS denetleyicisinde FLC ve ANN'ı birleştiren ANFIS tabanlı bir MPPT tekniği önermektedir. İki giriş, güneş radyasyonu ve sıcaklık kullanarak 400W PV dizisine bağlı bir DC-DC yükseltici tip DC-DC dönüştürücü için görev döngüsü sinyali üretir. Model, değişen hava koşulları ve kısmi gölge gibi çeşitli senaryolarda çalıştırılmıştır. Sonuçlar, ANFIS kontrolörünün hızlı izleme hızları ve yüksek dinamik yanıt verme özelliği ile iyi bir performans elde ettiğini göstermektedir. Standart P&O MPPT tekniği ile karşılaştırıldığında, önerilen ANFIS tabanlı MPPT tekniği daha etkilidir. ANFIS yöntemi de tasarım açısından karmaşıktır, hesaplama açısından yoğunur ve aşırı uyum sorunlarıyla karşılaşabilir. Ancak, bu aşırı uyum sorunları ML ve DL'nin gelişmiş veri ön işleme teknikleri kullanılarak çözülebilir.



Bu makalede (Vafaei et al., 2015), 4,4 kW şebeke bağlantılı bir PV sistemi için ANFIS-GA tabanlı hibrit bir MPPT yöntemi önerilmiştir. ANFIS kontrolörü, adaptif öğrenme için bulanık çıkarım ve sinir ağı eğitimini birleştirmektedir. GA optimizasyon yöntemi, ANFIS ağını eğitmek için en verimli veri kümesi örneklerini elde etmek için kullanılır. Model, farklı sıcaklık ve ışınlımlarda MATLAB/Simulink simülasyonu ile test edilmiştir. ANFIS-GA tekniği, izleme hızı, MPP güç salınımı ve dinamik yanıt verme açısından Standart P&O, IC, FLC ve ANN'den daha iyi performans göstermiştir. Bununla birlikte, birden fazla algoritmanın birleştirilmesi karmaşıklığı artırır ve tek bir kontrolördeki problem genel sistemin performansını etkiler. Bununla birlikte, ML ve DL algoritmalarının entegrasyonu, genel sistem doğruluğunu ve verimliliğini artırmak için büyük veri kümesi üzerinde eğitim yaparak sorunu bağımsız olarak çözer.

(Siddaraj et al., 2023)'de, solar ve batarya enerji depolama sistemlerinden (BESS) oluşan hibrit mikro şebeke sistemleri için PSO-ANFIS MPPT kontrolörü adı verilen entegre bir kontrol yaklaşımı sunulmuştur. Yöntem, şebekeye bağlı ve adalı mikro şebekelerin kararlı çalışmasını sağlar. PSO-ANFIS MPPT, geleneksel MPPT yöntemlerine göre daha hızlı yakınsama ve daha doğru maksimum güç noktası takibine sahiptir. Bununla birlikte, yüksek veri ve eğitim gereksinimleri, donanım doğrulama eksikliği ve uygun verimlilik ve maliyet analizi eksikliği gibi bazı dezavantajları vardır. Bu sorunları çözmek için ML veya DL tabanlı daha verimli MPPT algoritmaları düşünülmeli, eğitim gereksinimleri azaltılmalı ve gerçek uygulamalar için derinlemesine maliyet-fayda çalışmaları yapılmalıdır.

#### **2.1.4. AI, ML ve DL tabanlı MPPT Yöntemlerinin Literatür İncelemesi**

Yapay zekâ (AI), makine öğrenimi (ML) ve derin öğrenme (DL) endüstri 4.0 ve toplum 5.0'ın bel kemiğidir. Bu nedenle, solar PV sistemindeki uygulamalarına geçmeden önce kısa arka planlarını vurgulamak önemlidir. Bu nedenle, bu bölüm ilk olarak yapay zekâ, makine öğrenimi ve DL'nin arka planını vurgulamakta, ardından şebekeye bağlı PV sistemlerdeki uygulamalar üzerine bir literatür taraması yapmaktadır. Bu bölüm aşağıdaki şekilde ilerlemektedir: (a) AI açıklanmış, ardından (b) ML ve son olarak (c) DL kavramları sunulmuştur.

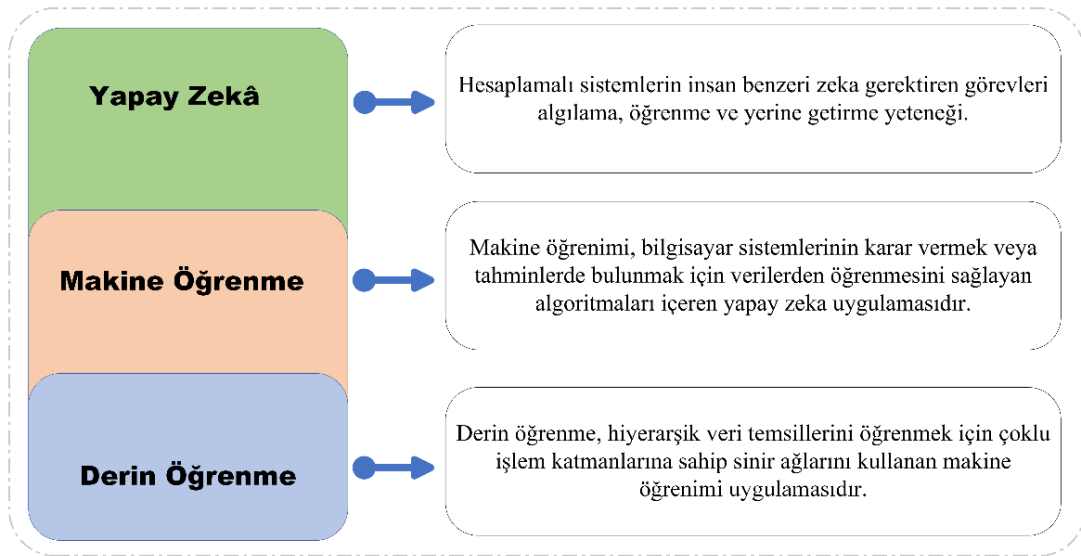
#### 2.1.4.1. AI, ML ve DL'nin Tanıtımı

AI, ML ve DL'nin temel ve kısa tanıtımı verilen alt bölümlerde açıklanmıştır.

- **Yapay Zeka (AI)**

AI, insan zekasını makinelerde kopyalamayı ve geliştirmeyi amaçlayan bir bilgisayar bilimi alanıdır. 20. yüzyılın ortalarında Alan Turing ve John McCarthy gibi öncüler hesaplamalı zekâ alanında öncü araştırmalar yapmış ve 1956 yılında 'yapay zekâ' terimini ortaya atmışlardır. O zamandan bu yana yapay zekâ, **Şekil 2.1**'de gösterildiği gibi ML ve DL gibi alt kümelerin ortaya çıkmasıyla uzun bir yol kat etmiştir.

Bu gelişmeler AI'yı teknolojinin ön saflarına taşımıştır ve her sektörde ve insan hayatının her alanında devrim yaratması beklenmektedir. Enerji sektöründe, zaman serisi tahmini, talep ve üretim tahmini gibi yapay zeka uygulamaları operasyonel verimliliği artırmış, arıza süresini azaltmış ve kaynak tahsisini optimize ederek maliyet tasarrufu ve sürdürülebilirliği artırmıştır (KARABİNAOĞLU et al., 2022).




Şekil 2.1. AI, ML ve DL'nin temel tanıtımı ve karşılaştırılması

- **Makine Öğrenimi (ML)**


ML, bilgisayarların açık bir programlama olmadan geçmiş verilerden kendi kendilerine öğrenmelerini ve gelişmelerini sağlayan yapay zekanın bir alt kümesidir. ML yaklaşımları üç ana kategoriye ayrılır: **Şekil 2.2**'de gösterildiği gibi denetimli öğrenme,

denetimsiz öğrenme ve pekiştirmeli öğrenme. Facebook, Google ve Uber gibi önde gelen şirketler ML'yi aşamalı olarak operasyonlarına entegre etmektedir. ML, akıllı şebeke optimizasyonu, sürdürülebilir enerji yönetimi ve hassas tahmin de dahil olmak üzere enerji sektöründe de büyük ilgi görmüştür (KARABİNAOĞLU et al., 2022).



Şekil 2.2. ML'nin, türlerinin ve türleri arasındaki farkların gösterilmesi

Denetimli Öğrenme (SL) ve denetimsiz öğrenme (USL) gibi, pekiştirmeli öğrenme (RL) de akıllı şebeke optimizasyonu, sürdürülebilir enerji yönetimi ve MPPT kontrolü dahil olmak üzere enerji sektöründe birçok uygulaması olan bir makine öğrenimi alt kümesidir.



Şekil 2.3. Pekiştirmeli öğrenme (RL) algoritmasının çalışma akışı

SL ve USL'den farklı olarak, RL bir başlangıç durumu, bir bitiş durumu ve çevreyi manipüle etmeye çalışan bir ajan içerir. Aracı bir durumdan diğerine hareket eder. Temsilci başarı için bir ödül (tanınma) alır, ancak başarısızlık için ödül veya tanınma almaz. Bu şekilde ajan çevreden öğrenir. Temsilci insan müdahalesi olmadan öğrenir, ödülleri en üst düzeye çıkarır ve cezasını en aza indirir. RL sürecinin iş akışı **Şekil 2.3**'te gösterilmiştir (Kofinas et al., 2017).

- **Derin Öğrenme (DL)**

DL, diğer özellik oluşturma tekniklerinden farklı olarak verilerden otomatik olarak özellik çıkaran bir makine öğrenimi alt kümesidir. Geleneksel makine öğreniminin aksine DL, verilerdeki karmaşık örüntüleri ve ilişkileri tanımlamak için birçok katmana sahip karmaşık sinir ağları kullanır. Bu derin mimari sayesinde DL, büyük veri setleriyle uğraşırken çok iyi performans gösterir ve özellikle denetimli öğrenme senaryolarında genellikle daha yüksek doğruluk elde eder. ML küçük veri setleri için hala etkili olsa da DL büyük miktarlardaki karmaşık verilerdeki ince desenleri tanımlamada üstündür.

**Çizelge 2.1.** ML ve DL modellerinin karakteristik özelliklerinin karşılaştırılması

| Özellik               | Makine Öğrenimi | Derin Öğrenme                      |
|-----------------------|-----------------|------------------------------------|
| Eğitim veri kümesi    | Küçük           | Büyük                              |
| Özellik mühendisliği  | Gerekli         | Otomatik                           |
| Sınıflandırıcı sayısı | Çok             | Az                                 |
| Eğitim süresi         | Kısa            | Uzun                               |
| Doğruluk              | İyi             | Büyük Veri Kümeleri için İyi       |
| Uygulama              | Geniş           | Farklı görevler için özel modeller |

Hem ML hem de DL girdi verilerine dayanır, ancak **Çizelge 2.1**'de listelendiği gibi çeşitli kavramlarda önemli ölçüde farklılık gösterirler. ML genellikle özelliklerin ve ön bilgilerin manuel olarak oluşturulmasını gerektirirken, DL özellikleri otomatik olarak çıkarma konusunda mükemmeldir ve bunları açıkça oluşturma ihtiyacını azaltır. ML daha az hesaplama ve eğitim süresi gerektirir ve bu nedenle daha küçük veri kümelerinde iyi çalışır, DL ise özellikle denetimli öğrenmede sürekli olarak yüksek doğruluk sağlamak için büyük ve etiketli veri kümelerinden yararlanır.

#### 2.1.4.2. Şebekeye Bağlı PV Sistemlerinde AI, ML ve DL: Literatür Taraması

Bu alt bölümde, şebekeye bağlı PV sistemlerinde yapay zekâ, makine öğrenimi ve DL dağıtımına ilişkin bir literatür taraması sunulmaktadır.

Bu makalede (Sharmin et al., 2022), SL MPPT kontrolörü, DC-DC yükseltici tip DC-DC dönüştürücü ile birlikte şebekeden bağımsız solar PV sistemi için kullanılmıştır. Önerilen ML modeli hesaplama açısından ucuzdur, uygulaması kolaydır ve P&O (%67,4 verimlilikle) gibi geleneksel yöntemlerden daha iyi performans göstererek yaklaşık %99,8 MPPT verimliliği elde eder. Bununla birlikte, kısmi gölgeleme için hareket kontrolünden yoksundur ve yük dalgalanmalarını dikkate almaz. DL yöntemleri, otomatik özellik çıkarma, büyük miktarda karmaşık veriyi işleme yeteneği ve kısmi gölgeler gibi değişen koşullara uyum sağlayan CNN ve LSTM gibi teknikler sayesinde bu sınırlamaların üstesinden gelebilir. Böylece MPPT'nin performansı geleneksel ML algoritmasına göre iyileştirilebilir.

Yazarlar tarafından (Kofinas et al., 2017)'de önerilen araştırma, DC-DC azaltan (buck) tipte dönüştürücülü bağımsız bir PV sistemi için RL'ye dayalı bir MPPT yöntemi tasarlamıştır. Daha az kurulum süresi gerektiren ve önceden sistem bilgisi gerektirmeyen RL tabanlı strateji, verimlilik ve yakınsama hızı açısından daha geleneksel yaklaşımlardan daha iyi performans göstermektedir. Çevrimiçi öğrenerek birçok duruma uyum sağlayabilir. Bununla birlikte, DL tabanlı MPPT algoritmalarının kullanılması, geçit birimi yapılarını kullanarak karmaşık veriler arasındaki uzun vadeli ilişkiyi çıkarma kabiliyeti nedeniyle sistemin verimliliğini ve doğruluğunu daha da artırabilir.

Yazarlar tarafından yapılan araştırma (Phan et al., 2020), P-V eğrisindeki birden fazla tepe noktasıyla başa çıkabilen hızlı ve istikrarlı bir performansa sahip, kısmen gölgeli PV sistemlerine sahip akıllı şebekeler için DRL tabanlı bir MPPT yöntemi sunmaktadır. Bu DRL algoritması, mevcut gücü en üst düzeye çıkarmak, pilleri verimli bir şekilde şarj etmek ve enerjiyi DC yüküne aktarmak için PV modül voltajını ayarlar. Ayrıca, bu DRL yaklaşımı P&O gibi geleneksel tekniklere kıyasla hızlı yanıt ve kararlılık sağlar. Bununla birlikte, LSTM kullanan DL, hızla değişen hava koşulları altında doğruluk sınırlamalarını hafifleterek verimliliği, uyarlanabilirliği ve veri yönetimini geliştirebilir.

DRL tabanlı bir MPPT algoritması, P-V eğrisindeki birçok tepe problemini ele alan, kısmen gölgeli PV sistemleri için hızlı ve verimli bir izleme yaklaşımı gerçekleştirmek için kullanılmıştır (Avila et al., 2020). MPPT, gerilim, akım ve güç

verileri kullanılarak optimize edilmiştir. DRL tabanlı bu MPPT, performans ve doğruluk açısından geleneksel MPPT kontrolörlerinden daha iyi performans göstermiştir. DC bağlantı voltajını, aktif / reaktif gücü düzenlemeden veya bir inverter kullanmadan MPPT'ye odaklanan bu DRL tabanlı MPPT tekniği, yükten önce bir DC-DC dönüştürücüye sahip bağımsız PV sistemleri için uygundur. Bununla birlikte, şebekeye bağlı PV sistemleri, karmaşıklığı artıran ve daha yüksek doğruluk gerektiren kararlı DC kuplajı gerektirir. Bu nedenle, DL'nin LSTM ile entegrasyonu, hızlı çevresel değişiklikler sırasında verimliliği, doğruluğu ve uyarlanabilirliği daha da artırabilir ve şebekeye bağlı PV sistemlerini stabilize edebilir.

(Roh, 2022)'deki yazarlar, önce DL algoritmasını kullanarak ışıınımı tahmin ederek ve ardından şebekeden bağımsız PV sistemleri için DC-DC yükseltici tip DC-DC dönüştürücüyü kontrol etmek için MPPT ile kullanarak birleşik bir yaklaşım kullanmışlardır. Bu strateji, geleneksel P&O yöntemine kıyasla daha verimli ve daha hızlı izleme sağlar. Bununla birlikte, ışıınım hızla dalgalandığında doğruluk sorunları ortaya çıkar. Bu nedenle, özellikleri otomatik olarak çıkaran, zamansal verileri işleyen ve geçit tasarımını kullanan LSTM ağı ile derin öğrenme kullanarak bu sınırlamaların üstesinden gelmek, MPPT'nin doğruluğunu, hızını ve esnekliğini artırabilir.

Güç kalitesini daha da iyileştirmek için, akıllı bir inverter, bir DC-DC yükseltici tip DC-DC dönüştürücü ve bir LCL filtresi kullanan şebekeye bağlı PV kurulumları için DNN tabanlı bir MPPT sistemi (Srinivasan & Ramalingam Balamurugan, 2022)'da sunulmuştur. Sistem IEEE 1547 gerekliliklerine uygun olmasına rağmen, sabit DNN modeli çevresel değişikliklerle başa çıkma esnekliğini sınırlamaktadır. LSTM gibi gelişmiş derin öğrenme teknikleri, sabit DNN tasarımlarına kıyasla hızla değişen güneş ışıınımı ortamlarında daha iyi performans gösterdikleri için verimliliği ve uyarlanabilirliği artırmak için önerilmektedir. LSTM kullanan DL, hızla değişen hava koşullarında doğruluk sınırlamalarını azaltarak verimliliği, uyarlanabilirliği ve veri yönetimini geliştirebilir.

Bu bölüm, geleneksel, akıllı ve hibrit MPPT kontrolörleriyle ilişkili zorlukların üstesinden gelmek için kullanılan çeşitli ML ve DL stratejileri hakkında bir literatür incelemesi sunmaktadır. Ayrıca bu bölüm, şebekeye bağlı PV sistemi için önerdiğimiz DL tabanlı LSTM MPPT kontrolörünün de temelini oluşturmaktadır. Mevcut ML DL MPPT yöntemleri ile önerilen LSTM MPPT algoritmaları arasında kritik bir karşılaştırmalı analiz bölüm 1.4'te sunulmuştur.



Tüm geleneksel, akıllı, hibrit, ML ve DL tabanlı MPPT kontrol stratejilerinin özellikleri **Çizelge 2.2'**de listelenmiştir.

## 2.2. Şebekeye Bağlı PV'nin İkinci Aşamasına İlişkin Literatür Taraması

Bu bölümde, şebekeye bağlı PV sistemlerin ikinci aşaması ile ilgili literatür çalışmaları sunulmuştur. İkinci aşamanın ana bileşenleri DC-bağlantı kondansatörü, DC-AC evirici, PLL, LCL filtresi ve şebekedir. Her bir bileşenin tasarımı, tipi, çalışması ve kontrolü Bölüm 3'te ayrıntılı olarak açıklanmaktadır. Birinci aşamadaki MPPT'ler ve yükseltici tip DC-DC dönüştürücüler, eviricinin girişi olan dc-bağlantı voltaj regülasyonunun kontrolünde önemli bir rol oynarken, LCL filtreleri harmonikleri en aza indirir. Bu ikinci aşamada evirici, PV dizisi tarafından üretilen gücü mikro şebekeye aktarmak için gerilim ve akım kontrol şemasını kullanır. Önceki bölümde (1.2), MPPT, yükseltici tip DC-DC dönüştürücü ve evirici ile entegre edilmiş şebekeye bağlı PV bu bölümün temeli olarak ele alınmıştır. Bu alt bölüm, şebekeye bağlı PV sistemler için dc-link voltaj regülasyonu ve evirici kontrol topolojileri üzerine son teknoloji araştırmalara odaklanmaktadır.

(T. K. Roy & Mahmud, 2017)'deki yazarlar, şebekeye bağlı bir solar PV sistemindeki aktif gücü kontrol etmek için güvenilir doğrusal olmayan uyarlanabilir geri adımlamalı kontrolör tasarladılar. Maksimum PV güç üretimi elde etmek için IC-MPPT ile donatılmış bir DC-DC yükseltici tip DC-DC dönüştürücü kullanılır. İnverter akımının kontrol edilmesi DC bağlantı gerilimini düzenler. Uyarlanabilir kontrolör, bilinmeyen sistem parametrelerinin çevrimiçi tahminini sağlar. Lyapunov kararlılık analizi kullanılarak, kontrolör tasarlanırken parametre belirsizlikleri ve harici bozulmalar dikkate alınır. Bu, çeşitli çalışma koşulları altında sağlamlık sağlar. Gerekli aktif gücü sağlamak için kontrolör şebekeye yüksek kaliteli akım enjekte eder. Sistem, kontrolörün performansını değerlendirmek için MATLAB/Simulink'te modellenmiş ve simüle edilmiştir.

Yazarlar tarafından iki aşamalı şebekeye bağlı tek fazlı bir PV sistemi önerilmiştir (Jagadeesan et al., 2022). Analitik MPPT, maksimum güç elde etmek için bir yükseltici DC-DC dönüştürücü tarafından kullanılmaktadır. Şebeke bağlantı gerilimi ve güç faktörü, DC-AC inverter kullanılarak birim değerinde tutulmaktadır. İnverterin dahili akım döngüsü PI ve harici gerilim döngüsü tarafından kontrol edilir. PV sistemi,



verimliliği artırmak için PV eğrisinin uygun tarafında çalıştırılır. MPPT'nin gerçek zamanlı verimliliği optimize edilmiş bir analiz tekniği kullanılarak değerlendirilir. DC-DC dönüştürücünün görev döngüsünün beklenen MPP'ye ve artıklık komutuna göre değiştirilmesi, yedek güç çalışmasına olanak tanır. Bu da enerji depolama mekanizmalarına olan ihtiyacı ortadan kaldırır. Önerilen sistemin modellenmesi için MATLAB/Simulink kullanılmış ve ardından deneysel olarak doğrulanmıştır.

(Krishna et al., 2021)'deki yazarlar, transformatörsüz şebeke bağlantılı bir solar PV sistemi için verimli bir aktif güç kontrol tekniği sunmaktadır. Maksimum güç, P&O MPPT ile yüksek kazançlı bir boost DC-DC dönüştürücü kullanılarak elde edilir. Çift aktif köprü (DAB) DC-DC dönüştürücü, bataryayı her iki yönde şarj ve deşarj eder. PV, batarya ve yük arasındaki optimum güç dengesi, akıllı bir sabit güç dengeleme algoritması ile elde edilir. DC şebeke gerilimi, sabit şebeke gücü kullanılarak düzenlenir. Gerilim kaynaklı invertere, dahili bir akım düzenleme döngüsü ve harici bir gerilim düzenleme döngüsü PI aracılığıyla şebekeye güç sağlar. PLL ve LCL filtreleri şebeke senkronizasyonu ve harmonik bastırma sağlar. Önerilen kontrol tekniğini farklı koşullar altında doğrulamak için sistem MATLAB'da modellenmiştir.

Yazarlar tarafından iki aşamalı şebekeye bağlı tek fazlı bir PV sistemi önerilmiştir (El Mezdi et al., 2023). Analitik MPPT, maksimum güç elde etmek için bir yükseltici DC-DC dönüştürücü tarafından kullanılmaktadır. DC bağlantı gerilimi inverter kontrolü kullanılarak düzenlenir, güç faktörü PV'den şebekeye sadece aktif güç aktarmak için bir tutulur. İnverterin dahili akım döngüsü PI ve harici gerilim döngüsü tarafından kontrol edilir. PV sistem, verimliliği artırmak için P/V eğrisinin uygun tarafında çalıştırılır. MPPT'nin gerçek zamanlı verimliliği optimize edilmiş bir analiz tekniği kullanılarak değerlendirilir. DC-DC dönüştürücünün görev döngüsünün beklenen MPP'ye ve yedekleme komutuna göre değiştirilmesi, yedek güç çalışmasına izin verir. Bu, enerji depolama mekanizmalarına olan ihtiyacı ortadan kaldırır. Önerilen sistemi modellemek için MATLAB/Simulink kullanılmış ve ardından deneysel olarak doğrulanmıştır.

(Sevilmi & Karaca, 2018)'nin yazarları, tek fazlı şebeke bağlantılı bir sistemde eviricinin şebeke gerilimi ile doğru ve hızlı senkronizasyonunun önemini vurgulamaktadır. Yazarlar üç fazlı SVPWM kontrollü şebeke bağlantılı bir inverteri MATLAB/Simulink'te simüle etmiş ve bir TMS320F28335 DSP kullanarak deneyler gerçekleştirmiştir. Simülasyon ve deneysel sonuçlar, bir faz kilitli döngü (PLL) algoritması kullanarak başarılı şebeke senkronizasyonunu doğrulamaktadır. Ayrıca, (Karaca & Bektas, 2016)'deki yazarlar da hem bağımsız hem de şebekeye bağlı

yenilenebilir enerji sistemlerinde basit harmonik eliminasyon (SHE) azaltımı için GA önermişlerdir. Ek olarak, PLL'nin döngü filtrelemesinde, (Sevilmiş & Karaca, 2021)'deki yazarlar, şebekeye bağlı güç sistemlerinde kararlı senkronizasyon elde etmek için inverter voltajının doğru fazını ve büyüklüğünü elde etmek için DC ofset reddetme tekniğini kullandılar.

**Çizelge 2.2'**de ayrıca şebekeye bağlı bir PV sistemde iki aşamalı çalışma üzerine yapılan son araştırmalar da listelenmektedir. Önceki bölümlerde, özellikle son teknoloji MPPT kontrolörlerinin kategorilerine, ilerlemelerine ve sınırlamalarına odaklanılmıştır. Bu bölüm özellikle DC bara gerilim regülasyonu, evirici kontrol topolojileri, filtre tasarımı ve önceki araştırmacılar tarafından şebekeye bağlı bir PV sisteminde aktif reaktif güç kontrolünü vurgulamayı amaçlamaktadır. Bir sonraki bölüm, en son teknoloji ile önerilen çalışma arasındaki karşılaştırmalı değerlendirmeye odaklanmaktadır.

### 2.3. Geçmişteki Zorluklar ve Önerilen Lstm Tabanlı Mppt'nin Kapsamı

Bu literatür taramasında, şebekeye bağlı PV sistemler için geleneksel, akıllı, hibrit ve makine/derin öğrenme tabanlı MPPT kontrolörleri üzerine geçmiş araştırmalar tartışılmaktadır. Buna ek olarak, evirici kontrol stratejileri de gözden geçirilmiştir. Ardından, derin öğrenme modelleri kullanan iki aşamalı şebekeye bağlı PV sistemler üzerine yapılan araştırmalar, zorluklar ve eksiklikler de dahil olmak üzere vurgulanmaktadır. Mevcut literatürdeki kısıtlamalara dayanarak, bu bölüm araştırmanın ihtiyacını ve kapsamını ortaya koymaktadır. Özet olarak, bu bölüm ilgili çalışmaları gözden geçirerek, derin öğrenme tabanlı iki aşamalı PV sistemlerle ilişkili açık zorlukları belirleyerek ve bu boşlukları ele almak için araştırma yönlerini belirleyerek araştırma bağlamını oluşturmaktadır.

Şebeke dışı ve şebekeye bağlı fotovoltaiikler (PV) için MPPT kontrolörlerinin geliştirilmesinde, performansı ve dolayısıyla doğruluğu ve verimliliği artırmak için gelişmiş teknikler kullanılarak önemli ilerlemeler kaydedilmiştir. Bu derleme, özellikle şebekeden bağımsız ve şebekeye bağlı PV enerji üretimi için geleneksel, akıllı, hibrit, yapay zekâ ve derin öğrenme yaklaşımları dahil olmak üzere çeşitli MPPT algoritmalarına kapsamlı bir genel bakış sunmaktadır. Tartışılan temel konular arasında hava değişimleri sırasında MPP etrafındaki dalgalanmalar, DC bağlantı voltajı kararsızlığı ve inverter çıkışındaki harmonik bozulma yer almaktadır. Bununla birlikte, kararlılık, verimlilik ve çevresel dinamiklere uyarlanabilirlik açısından hala sınırlamalar

vardır. Önerilen model, iki seviyeli şebeke bağlantılı bir sistemde DC-DC dönüştürücülerin gelişmiş MPPT kontrolü için stack bir LSTM ağ mimarisi sunmaktadır. Bu veri odaklı yaklaşım, mevcut literatürde tanımlanan zorlukların üstesinden gelmeyi amaçlamaktadır.

(Kulaksiz & Akkaya, 2012a)'daki yazarlar, GA optimizasyonlu bir ANN ve eviricinin PI kontrolünü kullanarak bağımsız bir PV sistemi için bir MPPT uygulamışlardır. ANN, G ve T verilerine dayalı olarak MPP'deki gerilimi belirlemek için çevrimdışı olarak eğitilmiştir. Bu, ANN'yı DSP/mikrodenetleyici uygulaması için yeterince küçük hale getirmektedir. Geleneksel P&O MPPT'nin aksine, PI kontrolördeki adım değişiklikleri salınım olmadan MPP'yi takip eder. Simülasyonlar ve deneyler, sabit adım boyutu yaklaşımına göre daha az hata ile daha hızlı izleme göstermektedir. Bununla birlikte, basit bir ANN yapısı doğruluğu ve uyarlanabilirliği sınırlayabilir. Buna karşılık, bu tezde sunulan araştırma, şebekeye bağlı bir PV sistemi için MPPT uygulamak üzere stack bir LSTM derin öğrenme modeli kullanmaktadır. Tezde kullanılan basit ANN ile karşılaştırıldığında, stack LSTM MPPT için daha yüksek doğruluk ve uyarlanabilirlik sağlar. Ayrıca, makalede ayrı MPPT ve inverter kontrolleri uygulanırken, önerilen çalışma MPPT ve inverterin droop kontrolünü sırasıyla LSTM ve PI kontrolörleri kullanarak gerçekleştirmektedir. Bu, inverter kontrolünün basitliğini korurken maksimum güç elde etmek için derin öğrenmenin kullanılmasına izin verir.

(Roh, 2022)'deki yazarlar, G'yi tahmin etmek ve çıkış gücünü maksimize etmek için DL tabanlı bir MPPT kontrol algoritması sunmuşlardır. Prosedür, MPP'nin mevcut değerini tahmin etmek için sıcaklık ve ışıınım verilerini kullanır. Algoritma, mevcut P&O MPPT tekniklerine kıyasla daha iyi performansa sahiptir. Bununla birlikte, çalışmada veri kümesinin boyutu, eğitim ve test için gerekli veri bölümlenmesi ve kullanılan gizli katman sayısı dahil olmak üzere DL model mimarisinin ayrıntıları eksiktir. Bu çalışmada yazarlar özellikle G seviyelerini tahmin etmiş, ardından MPPT algoritmasını uygulamış ve sonuçları P&O MPPT kontrolörüyle karşılaştırmıştır. Bu tezde önerilen çalışmada, MPPT kontrolörü olarak LSTM DL yöntemi kullanılmış ve sonuçlar geleneksel veya diğer akıllı MPPT'ler yerine diğer DL modeli olan FF-DNN ile karşılaştırılmıştır. Ek olarak, önerilen araştırma, PV dizisi tarafından üretilen aktif gücü elektrik mikro şebekesine aktarmak için inverter kontrolü de sağlamıştır.

(Ab-Belkhair et al., 2020)'deki yazarlar, 50 kW hibrit PV/Rüzgâr sistemi için bir MPPT algoritması geliştirmek üzere bir DNN kontrolörü kullanmaktadır. MPPT algoritması, 66.000 elemanlı bir veri kümesi ile bir DNN öğrenme algoritması

kullanılarak formüle edilmiş ve 20kW'lık bir PV dizisi ve bir yükseltici tip DC-DC dönüştürücü ile MATLAB'da simüle edilmiştir. DNN kontrolörünün mimarisi 1000 gizli katman nöronu ve bir çıkış nöronundan oluşmaktadır. Ayrıca yazarlar, inverter kontrolü için başka bir DNN kontrolörünü entegre ederek hem MPPT hem de inverter kontrolünü ele alarak anlayışı ilerleten kapsamlı bir yaklaşım sunmaktadır. Araştırma, DNN denetleyicisindeki en uygun gizli katman ve birim sayısının belirlenmesini araştırmaktadır. Özellikle, biri MPPT ve diğeri inverter kontrolü için 1000 gizli nörona sahip iki DNN modeli, toplam 66.000 veri örneği kullanılarak kullanılmıştır. Buna karşılık, bu tezde önerilen model, 1 milyon veri noktası kullanarak (64+32) gizli nöronlu LSTM ve inverter kontrolü için bir PI denetleyici kullanmaktadır. Genel olarak, daha fazla veri üzerinde eğitilen önerilen model daha az karmaşıklıkla daha üstün doğruluk elde etmektedir.

Yazarlar (Srinivasan & Ramalingam Balamurugan, 2022), şebekeye bağlı PV sistemleri için DNN tabanlı bir MPPT algoritmasını, şebekeye bağlı evirici için Örümcek Maymun Optimizasyonu (SMO) ile ayarlanmış bir Orantılı Rezonans (PR) kontrolörü ile birleştiren yeni bir yaklaşım sunmuşlardır. DNN, Bald Eagle Search (BES) kullanılarak optimize edilmiş çoklu gizli katmanlara sahip bir Tekrarlayan Sinir Ağından (RNN) oluşmaktadır. Bununla birlikte, çalışma, veri örneği miktarını, gizli katman ağ yapısını ve G varyasyonunun PV performansı üzerindeki etkisini göz ardı ederek yalnızca hücre T varyasyonuna odaklanan bir hedef veri kümesini dikkate almaktadır. Ayrıca, yazarlar inverter kontrol kısmında bir PR kontrolörü kullanmaktadır. Buna karşılık, bu tezde önerilen araştırma, RNN'lere kıyasla uzun vadeli bağımlılıkları yakalama konusundaki üstün yeteneği nedeniyle MPPT kontrolörü olarak LSTM'yi kullanmaktadır. LSTM'nin seçimi, RNN'lerle ilişkili kaybolan gradyan sorununu ele alan mimarisi ile motive edilmiştir. LSTM için optimizasyon sürecini geliştiren Adam optimizier, özellikle zaman serisi veri uygulamalarında derin sinir ağı ağırlıklarını optimize etmede BES'ten daha etkili olduğunu kanıtlamıştır. Karmaşıklığı yönetmek için, evirici tarafında, PR denetleyicisine kıyasla daha az hesaplama karmaşıklığı ile gerçek zamanlı kontrol görevlerindeki etkinliği ile bilinen basit bir PI denetleyicisi kullanılır, bu da basitleştirilmiş uygulamaya ve iyileştirilmiş genel sistem verimliliğine katkıda bulunur.

(Dharma Raj et al., 2023)'te yazarlar 230W solar PV dizisi, 6 türbinli 575V hat gerilimli rüzgâr sistemi ve enerji depolama için kurşun-asit bataryayı entegre eden şebekeye bağlı hibrit bir sistemi tanımlamaktadır. MPPT denetleyicisi olarak katman başına 120 nöron içeren beş katmanlı bir BiLSTM ağı kullanılmış, ortalama karesel hata

kaybı ve ROA optimizasyonu kullanılarak 70-30 bölünmüş veri kümesi üzerinde eğitilmiştir. Sistem, %98,23 MPPT verimliliği ve %0,88 evirici çıkış gerilimi Toplam Harmonik Bozulma (THD) ile 2,83 MW toplam güç tüketimi elde etmektedir. Bununla birlikte, BiLSTM yapısının basitliği gibi doğruluğu ve uyarlanabilirliği etkileyebilecek potansiyel sınırlamalar kabul edilmektedir. Ayrıca, çalışmada ağdaki toplam nöron sayısı, veri ön işlemenin karmaşıklığı veya inverter kontrol yaklaşımı belirtilmemiştir. Buna karşılık, tez için önerilen araştırma, 2 katmanlı ve toplam 96 gizli nöronlu (64+32) stack LSTM tabanlı bir MPPT denetleyicisi kullanarak 100 kW'lık önemli bir PV dizisine sahip şebekeye bağlı bir PV sistemini tanıtmaktadır. Titiz bir veri ön işleme stratejisi, Z-skor normalizasyonunu ve histogram, kutu grafiği ve korelasyon matrisi analizleri yoluyla kapsamlı görselleştirmeyi içerir. Sistem, uygulamayı kolaylaştırmak ve hesaplama karmaşıklığını azaltmak için 12 anahtarlı 3 seviyeli sinüzoidal darbe genişlik modülasyonu bir inverterin yanı sıra inverter kontrolü için Oransal-İntegral (PI) kontrolörleri içerir. 98,2'lik bir verimlilik elde eden önerilen araştırma, yukarıda bahsedilen yazarların araştırmalarına kıyasla sistem kapasitesi, kontrolör karmaşıklığı ve metodolojik titizlik açısından iyileştirmeler göstermektedir.

**Çizelge 2.3.** Yaygın olarak kullanılan MPPT yöntemleri arasında kısa bir karşılaştırma


| Yöntemi          | Avantajları                                                                                    | Sınırlamalar                                                                                                                  |
|------------------|------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------|
| <b>P &amp; O</b> | Basit tasarım, Kolay uygulama, Düşük karmaşıklık, Hızlı Hız                                    | MPP çevresinde salınımlar, Düşük verimlilik                                                                                   |
| <b>IC</b>        | P&O'dan daha düşük salınımlar, P&O'dan daha yüksek verimlilik                                  | P&O'ya kıyasla karmaşık tasarım, P&O'dan daha düşük hız                                                                       |
| <b>FLC</b>       | Belirsiz koşullar altında daha iyi performans sunar, Değişken adım boyutu D sağlar             | ML becerilerine sahip değildir, FLC kuralları uzman bilgisi gerektirir, MPC tahmin parametrelerine karşı hassastır            |
| <b>MPC</b>       | Belirsiz koşullar altında daha yüksek verimlilik, FLC, MPC, IC ve P&O'dan daha yüksek doğruluk | Gelişmiş ML algoritmalarından daha düşük doğruluk, Büyük veri uygulamaları için daha düşük doğruluk                           |
| <b>ANN</b>       | Belirsiz koşullar altında daha yüksek verimlilik, FLC, MPC, IC ve P&O'dan daha yüksek doğruluk | Gelişmiş ML algoritmalarından daha düşük doğruluk, Büyük veri uygulamaları için daha düşük doğruluk                           |
| <b>DNN</b>       | Bellek öğelerinin eklenmesi doğruluğu artırdı, Belirsiz ortamın büyük verileriyle ilgilenir    | Büyük veriler için büyük eğitim süresi ancak gradyan kaybolma sorunu, Yüksek karmaşıklık (gizli birimlere ve veriye bağlıdır) |

DL'nin PV için bir MPPT kontrolörü olarak kullanılması, halen araştırılmakta olan yeni bir araştırma alanıdır. Geleneksel ve akıllı MPPT kontrolörleri kullanan PV sistemleri için çok sayıda araştırma yapılmıştır, ancak DL algoritmaları kullanılarak çok fazla araştırma yapılmamıştır, bu nedenle karmaşıklığı azaltırken doğruluğu artırmak için ek araştırmalara ihtiyaç vardır. DL tabanlı MPPT kontrolörünün diğer MPPT kontrolörleriyle karşılaştırması **Çizelge 2.3**'te vurgulanmıştır. Son on yılda, sistem karmaşıklığı tarihsel olarak PV sistemlerinde AI algoritmalarının kullanımının önünde önemli bir engel olmuştur. DL algoritmaları, hava durumu parametrelerinin hızlı değişimlerine rağmen düşük hata ve yüksek doğrulukla MPPT için kullanılabildiğinden son zamanlarda dikkat çekmektedir. Önerilen LSTM tabanlı MPPT kontrolörü, FFNN ve geleneksel P&O'dan daha yüksek doğruluk elde ederken şebekeye bağlı PV sisteminin karmaşıklığını azaltmak için yalnızca 96 gizli nöron kullanır. Önerilen MPPT kullanılarak üretilen güç daha sonra basit ve daha az karmaşık bir PI denetleyici içeren inverter yapısı üzerinden şebekeye iletilir. Bununla birlikte, eğitim süresi genel işlem birimleri kullanılarak dakikalardan saniyelere kadar iyileştirilebilir.

Bu sorunları ele almak için akademide DL tabanlı çözümler önerilmiştir. Bu tezde, şebekeye bağlı PV sistemlerindeki iki kritik sorunu çözen yeni bir DL LSTM tabanlı MPPT yöntemi: (a) stack LSTM tabanlı bir MPPT denetleyicisi kullanarak 100 kW'lık bir PV dizisinden maksimum gücü elde etmek, (b) şebekeye bağlı bir PV sisteminde DC voltajını ve üç seviyeli bir inverterin çalışmasını kontrol etmek. Önerilen araştırma temel olarak MPPT kontrolörü ve DC bağlantı voltajı kontrolüne odaklanmakta ve aktif gücü şebekeye aktarmaktadır. DC bağlantı voltajı kontrolü şebekeye bağlı PV sistemlerde çok önemlidir çünkü eviricinin girişindeki düzgün ve kararlı bir DC bağlantı voltajı, eviricinin çıkış tarafındaki harmonikleri azaltma ve şebekeye kararlı güç enjeksiyonu sağlama eğilimindedir. İlk aşamada kullanılan PV dizisi, yükseltici tip DC-DC dönüştürücü, MPPT denetleyici gibi temel bileşenler modellenmiş, tasarlanmış ve **Bölüm 3**'te açıklanmıştır. Benzer şekilde, önerilen stack LSTM tabanlı MPPT'nin modellenmesi, tasarımı, çalışması, türleri, eğitimi ve testine dayalı ayrıntılı açıklama **Bölüm 4**'te açıklanmıştır.

### 3. MATERYAL VE YÖNTEM

Bu bölümde, önerilen çalışmada kullanılan araştırma arka planının, materyallerin ve yöntemlerin temel kavramları açıklanmaktadır. Bu tezde, (a) birinci kademe ve (b) ikinci kademe olmak üzere iki kademeye ayrılan 100 kW'lık üç fazlı çift kademeli şebeke bağlantılı bir PV sistem ele alınmıştır. Bu tezde kullanılan birinci ve ikinci aşamada kullanılan tüm bileşenleri gösteren blok diyagram Şekil 3.1'de gösterilmektedir. Birinci aşama güneş paneli, MPPT denetleyici ve yükseltici tip DC-DC dönüştürücüden oluşmaktadır. İkinci aşama ise inverter kontrolü, DC bara gerilimi kontrolü ve şebekeye güç aktarımının kontrolünü içermektedir.



Şekil 3.1. Önerilen araştırmanın birinci ve ikinci aşamasında kullanılan bileşenler

Blok diyagramından, PV dizisinin Işınım (G) ve Sıcaklık (T) değerlerine bağlı olarak değişken DC gerilimi ürettiği açıktır. PV geriliminin seviyesi bir DC-DC yükseltici tip DC-DC dönüştürücü kullanılarak artırılır. Artan voltaj seviyesi, güç dengesini korumak ve iletim kablolarındaki düşük kayıplarla uygun hale getirmek için akım seviyesini azaltmaya yardımcı olur. Yükseltici tip DC-DC dönüştürücünün anahtarı, PV panelinden maksimum gücü elde eden bir MPPT kontrolörü kullanılarak kontrol edilir. MPPT kontrolörü, MPP'deki akımı ve gücü belirleyen MPP'de bir referans voltaj sağlar. MPP'deki çıkarılan voltaj gerçek PV voltajıyla karşılaştırılır ve hata sinyali, yükseltici tip DC-DC dönüştürücünün anahtarının darbe genişliğini ayarlamak için Darbe Genişlik Modülasyonu (PWM) için bir referans sinyali olarak kullanılır. Bu tez çalışmasında kullanılan temel bileşenlerin listesi aşağıda verilmiştir:

- Solar PV Dizisi
- Yükseltici tip DC-DC dönüştürücü
- MPPT Denetleyici
- Şebeke Bağlantılı İnverter
- Darbe Genişlik Modülasyonu
- Faz Kitleme Döngüsü

Bu bölümde ayrıca tezin birinci ve ikinci aşamalarında kullanılan tüm elektronik bileşenlerin modellenmesi, tasarımı ve çalışması da ele alınacaktır.

### 3.1. Şebekeye Bağlı PV Sistemin İlk Aşaması

PV paneli, yükseltici tip DC-DC dönüştürücü ve MPPT kontrolörü, şebekeye bağlı PV sisteminin ilk aşamasındaki önemli unsurlardır. PV dizisi güneş enerjisini ayarlanabilir DC gücüne dönüştürür. Yükseltici tip DC-DC dönüştürücü, PV gerilimini inverter için uygun giriş seviyesine yükseltir. MPPT kontrolörü, yükseltici tip DC-DC dönüştürücünün görev döngüsünü kontrol ederek dalgalı koşullar altında optimum güç çıkarımı için çalışma noktasını optimize eder. Her bir bileşenin ayrıntılı açıklaması bu alt bölümde verilmektedir.

#### 3.1.1. Solar PV Panel

Bir solar PV hücresi, güneş ışığını "Fotovoltaik Etki" kullanarak elektrik enerjisine dönüştürmek için kullanılan en küçük birimdir ("Photovolt. Mater. Electron. Devices," 2018). Güneş ışığının varlığında bir güneş pilinin çalışma prensibi **Şekil 3.2**'de gösterilmiştir.


Yüksek verimlilik ve düşük maliyet nedeniyle silikon, solar PV hücrelerinde en sık kullanılan yarı iletken malzemelerden biridir. Güneş pili, elektrik üretmek için güneş ışığını kullanan PV sisteminin en küçük bileşeni ve yapı taşıdır. PV hücrelerinin kombinasyonu istenen elektrik aralığını üretmek için kullanılır ve bu kombinasyon genellikle (a) PV hücresi, (b) PV modülü, (c) PV paneli ve (d) PV dizisi olarak adlandırılır.



Aşağıdaki alt bölümde, ilk olarak fotovoltaiik etki tanımlanmakta, daha sonra PV hücre, dizi ve modül gibi PV sistem bileşenleri açıklanmakta ve bunları bir PV hücrenin tasarımı ve çalışması takip etmektedir.

### 3.1.1.1. Fotovoltaiik Etki

"Fotovoltaiik etki", silikon gibi yarı iletken bir malzeme güneşten gelen fotonları emdiğinde ve elektronlar yaydığında ortaya çıkan bir olgudur. Bu serbest elektronlar ilgili plakalar boyunca akar ve yarı iletken malzemedeki bu serbest elektronların akışı akımı oluşturur (Mertens, n.d.).



Şekil 3.2. Solar PV hücresinin çalışma prensibi

Yazarlar tarafından (Mukerjee & Thakur, 2011)'de belirtildiği gibi fotovoltaiik süreçte yer alan ana adımlar aşağıda listelenmiştir:

- **Işık Absorpsiyonu:** Güneşten gelen ışık, güneş pilinin yarı iletken malzemesi tarafından emilir. Soğurulan fotonlar, yarı iletken malzemenin elektronlarını serbest elektronlar haline getirmek için uyarır.
- **Yük taşıyıcılarının ayrılması:** Yarı iletken malzemenin elektrik alanı bu elektronları ayırır. Hücrenin pozitif tarafı elektronları çeker ve pozitif taşıyıcılar hücrenin negatif tarafına doğru çekilir.
- **Akım Akışı:** Elektronların pozitif hücreden negatif hücreye doğru bu akışı elektrik akımı oluşturur.


Bir güneş pilinin genel verimliliği, optik kayıplar, taşıyıcı kayıpları ve termal kayıplar nedeniyle düşüktür, bu nedenle bu işlemle üretilen elektriğin verimliliği, gelen ışığın yüzdesidir. Piyasada, bir güneş pilinin ortalama verimliliği %15 ila 17 civarındadır, son zamanlarda %20 verimliliğe sahip güneş pilleri de ticari olarak mevcuttur (Morales et al., 2019). Yarı iletken bilim insanları, güneş panellerinin verimliliğini artırmak için yeni malzeme ve tasarımlar araştırmaya devam etmektedir.

### 3.1.1.2. PV Sistemin Yapı Taşları

Bir PV modülü, istenen voltajı elde etmek için paralel ve seri olarak bağlanan güneş pilleri grubudur. PV panel genellikle güneş modülleri ile eş anlamlı olarak kullanılır ve bu da belirli bir miktarda güç üretebilen tüm bir sistemi oluşturmak için bir araya getirilmiş bir grup güneş hücresini tanımlar. Bir PV dizisi, daha büyük bir güneş enerjisi sistemi oluşturmak için birleştirilen bir güneş panelleri koleksiyonudur.

### 3.1.1.3. Bir PV Hücresinin Tasarımı ve Çalışması

Bir solar PV hücresinin çalışma prensibi, ters kutuplu bir PN bağlantı diyotu gibidir. Güneş ışığı sırasında güneş ışığını veya foto enerjiyi elektrik enerjisine dönüştürmek için çalışır ve geceleri güneş ışığı olmadığında küçük bir "karanlık akım" üretir (Ito et al., 2008).



Şekil 3.3. Bir PV hücresinin tek diyot modeli

Bu tezde, istenen 100 kW çıkış gücünü elde etmek için modül başına toplam 96 hücre, dizi başına 5 seri bağlı modül ve 65 paralel dizi dikkate alınmıştır. Önerilen PV dizisinin maksimum gücü verilen denklem kullanılarak hesaplanmıştır;  $P_{pv} = P_{max} * N_p * N_s$ , bu da  $315*65*5=100,2$  kW verir. Basitlik ve hassasiyet göz önünde bulundurularak, PV dizisinin tek diyotlu eşdeğer modeli, (Beniysa et al., 2019), (Anani & Ibrahim, 2020)'de yazarlar tarafından da kullanılan **Şekil 3.3**'te gösterildiği gibi ele alınmıştır. PV hücrelerin güç üretimi temel olarak güneş ışıınımı (G) ve güneş hücresi sıcaklığındaki (T) değişimlerden etkilenmektedir.

PV hücrenin tek diyotlu modelinde, toplam akım denklem (3.1)'de modellendiği gibi Kirchhoff'un Akım Kanunu kullanılarak elde edilir. Işık akımı, diyot akımı ve şönt akımı dahil olmak üzere tüm akımların değerleri yerine konulduktan sonra, nihai çıkış akımı denklem (3.2)'de modellenir. Şönt direncinin değeri genellikle çok yüksek tutulduğu için şönt akımı çok küçük olacaktır. Bu nedenle, küçük şönt akımı ihmal edildikten sonra denklem (3.2), denklem (3.3) olarak daha da basitleştirilebilir. Matematiksel model, güneş pili konfigürasyonlarının tanıtılmasıyla daha da geliştirilebilir, bu nedenle denklem (3.4), seri ve paralel konfigürasyonlardaki güneş pili sayılarını kullanan nihai güncellenmiş akım denklemidir.

$$I = I_{ph} - I_d - I_{sh} \quad (3.1)$$

$$I = I_{ph} - I_o \{ \exp[q(v + IR_s)AKT] - 1 \} - \{(v + IR_s)R_{sh}\} \quad (3.2)$$

$$I = I_{ph} - I_o \{ \exp[q(v + IR_s)AKT_j] - 1 \} \quad (3.3)$$

$$I = N_p I_{ph} - N_p I_o \{ \exp[q(v + (R_s N_s / N_p))AKT_j] - 1 \} \quad (3.4)$$

Denklem (3.4), hem seri hem de paralel hücre düzenlemelerini dikkate alarak güneş pillerinin özelliklerini açıklamaktadır. Işık akımı ve şönt akımı kullanan bu denklemler, G ve T gibi harici parametrelerdeki değişimleri dikkate alır. Işık akımı, aydınlatılan hücrede akan akımı temsil ederken, şönt akımı güneş hücresinin şönt direncinden akar. Takip eden listede sembol tanımları ve (3.1)'den (3.4)'e kadar olan denklemlerde kullanılan çeşitli parametrelerin kısa açıklamaları kapsamlı bir şekilde verilmektedir.

$N_s$  : Dize başına seri bağlı modüller

$N_p$  : Paralel bağlı diziler

$I_{ph}$  : Foto Akım

- $I_d$  : Diyot akımı  
 $I_s$  : Seri akımı  
 $I_{sh}$  : Şönt akım  
 $R_{sh}$  : Şönt direnci  
 $R_s$  : Seri direnç  
 $q$  : Coulomb cinsinden elektrik yükü ( $1.602 * 10^{-23}C$ )  
 $K$  : Sabit Boltzmann ( $1.38 * 10^{-23}J/K$ )  
 $T_j$  : Eklem sıcaklığı  
 $A$  : İdeallik faktörü

Sıcaklıktaki değişim, güneş pilindeki seri direnci ve doygunluk akımını etkiler (bkz. Denklem 3.4), bu da hücre verimliliğinde bir düşüşe neden olabilir. MPPT kontrolörü, artan seri direnci hesaba katarak ve ideal voltaj seviyelerini koruyarak, bu etkileri telafi etmek için yükseltici tip DC-DC dönüştürücünün görev döngüsünü değiştirir. Öte yandan, aydınlatılmış hücrede akan akımı temsil eden fotoakım, esas olarak güneş ışıınının değişiminden etkilenir. MPPT kontrolörü, hücre çıkışını en üst düzeye çıkarmak için yükseltici tip DC-DC dönüştürücünün görev döngüsünü ayarlar, maksimum güç noktasına senkronize eder ve ışıınındaki dalgalanmalara rağmen verimli performans sağlar. Dolayısıyla, hücre sıcaklığı ve güneş ışıınındaki değişimler solar PV hücresinin performansını ve verimliliğini etkiler (Bhavani et al., 2023).

Önerilen modelde, istenen 100 kW çıkış gücünü elde etmek için dizi başına 5 seri bağlı modül ve 65 paralel dizi bağlanmıştır. Önerilen modelin Simulink MATLAB© ortamında uygulanan tasarım parametreleri **Çizelge 3.1**'de listelenmiştir.

**Çizelge 3.1.** Önerilen PV dizisinin tasarım parametreleri

| Sembol    | Değişkenin Adı                   | Değer    |
|-----------|----------------------------------|----------|
| $N_s$     | Seri bağlı modül sayısı          | 5        |
| $N_p$     | Paralel bağlı modül sayısı       | 66       |
| $V_{oc}$  | Açık devre gerilimi              | 64,2 V   |
| $V_{mp}$  | Maksimum güç noktası voltajı     | 54,7 V   |
| $I_{sc}$  | Kısa devre akımı                 | 5,95 A   |
| $A$       | İdeallik faktörü                 | 0.95     |
| $\alpha$  | $I_{sc}$ için Sıcaklık Katsayısı | 0.016    |
| $\beta$   | $V_{oc}$ için Sıcaklık Katsayısı | -0.27    |
| $P_{max}$ | Maksimum Güç                     | 315 Watt |
| $k$       | Kompanzasyon Faktörü             | 3        |


Bu bölümde ayrıca yükseltici tip DC-DC dönüştürücünün model tasarımı ve ardından PV dizisinin maksimum gücünü çıkaran ve DC bağlantı voltaj regülasyonunda da önemli bir destek olan yükseltici tip DC-DC dönüştürücünün daha yüksek çıkışını düzenlemek için yükseltici tip DC-DC dönüştürücünün anahtarını kontrol eden son teknoloji MPPT algoritması ile devam etmektedir.

### 3.1.2. Yükseltici tip DC-DC dönüştürücünün Formülasyonu ve Tasarımı

İlk aşamanın önemli bir bileşeni olan yükseltici tip DC-DC dönüştürücüyü tanımak için, bu tezde yükseltici tip DC-DC dönüştürücünün çalışma prensibi ve tasarımı anlatılmakta ve ardından tanıtımı yapılmaktadır.

#### 3.1.2.1. Yükseltici tip DC-DC dönüştürücüye Giriş

Bir yükseltici tip DC-DC dönüştürücü, çıkış voltajı giriş voltajından daha büyük olan bir DC-DC dönüştürücüdür. Giriş DC voltaj seviyesini artırdığı için 'yükseltici' dönüştürücü olarak da bilinir (Ayop & Tan, 2018).



Şekil 3.4. Bir yükseltici tip DC-DC dönüştürücünün şematik diyagramı

Yükseltici tip DC-DC dönüştürücünün tasarımında kullanılan ana elektronik bileşenler Şekil 3.4'te gösterildiği gibi kapasitör, indüktör bobini, yüksek frekanslı anahtarlar ve diyottur. Tek aşamalı şebekeye bağlı PV sistemlerin aksine, iki aşamalı şebekeye bağlı PV sistemler, PV paneller tarafından üretilen DC gücü AC elektriğe dönüştürmeden önce bir ara gerilime yükseltmek için yükseltici tip DC-DC dönüştürücü

kullanır. DC-bara voltajını uygun seviyede tutmak ve PV panellerin her zaman en yüksek verimlilikte çalışmasını sağlamak için iki aşamalı sistemdeki MPPT kontrolörü, PV panellerin çıkışına bağlı olarak yükseltici tip DC-DC dönüştürücünün görev döngüsünü kontrol eder (Yaosuo Xue et al., 2004). (Ayop & Tan, 2018; Madouh et al., 2012; Rajkumar & Rathinam, 2023)'deki yazarlar tarafından listelenen yükseltici tip DC-DC dönüştürücünün temel faydaları aşağıda verilmiştir:

- İki aşamalı şebekeye bağlı PV sisteminin verimliliğini artırmayı destekler.
- Daha düşük harmonik bozulma ve güç kayıpları ile daha yüksek güç kalitesi sunan voltaj ve akımın düzenlenmesine yardımcı olur.
- Panelden mümkün olan maksimum enerjinin alınmasını ve şebekeye iletilmesini garanti eden MPPT algoritmaları ile donatılmıştır.
- Gerilim seviyesini ayarlayarak esnekliği artırır ve iki aşamalı şebekeye bağlı PV sisteminin performansını iyileştirir.
- Gerilim seviyelerini kontrol edebilir, elektrik şebekesinin stabilizasyonuna katkıda bulunabilir ve güvenilir enerji üretimini garanti edebilir.


İki aşamalı şebekeye bağlı PV sistemlerinde, güneş panelleri tarafından üretilen DC voltajını artırmak için bir yükseltici tip DC-DC dönüştürücü gereklidir. Bu voltaj artışı MPPT algoritmasının performansını ve bir sonraki inverter aşamasının verimliliğini artırır. Genel sistem verimliliğini ve enerji üretimini iyileştirmek için yükseltici tip DC-DC dönüştürücü, gerilimi invertere uygulanmadan önce ideal seviyeye etkili bir şekilde yükselten bir ara adım görevi görür. Alt bölüm ayrıca şebekeye bağlı PV sisteminin çalışması ve tasarımı ile devam etmektedir.

### 3.1.2.2. Boost Konvertörün Çalışma Prensibi

Kondansatör, diyot, yüksek frekans anahtarı ve indüktör, yükseltici dönüştürücünün ana elektronik parçalarıdır. Yüksek frekanslı anahtar (MOSFET veya IGBT) genellikle yükseltici dönüştürücünden gerekli çıkış voltajını elde etmek için kullanılır (Alhejji & Mosaad, 2021).


Dönüştürücünün iki çalışma modu vardır (a) anahtar AÇIK modu ve (b) anahtar KAPALI modu. ON modunda, giriş kaynağı **Şekil 3.5**'te gösterildiği gibi giriş tarafı indüktörüne bağlıyken anahtarlama cihazı açılır. Giriş akımı kapalı anahtardan ve indüktörden geçer. İndüktör akımı arttıkça manyetik alan artacak ve enerjiyi

elektromanyetik alan şeklinde depolayacaktır (Mohan et al., 2003). Anahtar daha uzun bir süre açık bırakılırsa, başlatma süresi ve görev döngüsü uzayacak ve yükseltici tip DC-DC dönüştürücünün çıkış voltajı da artacaktır.



Şekil 3.5. Anahtar ON (kapalı) olduğunda yükseltici tip DC-DC dönüştürücünün çalışması

Anahtar KAPALI modunda akım azalmaya başlayacak ve manyetik alan çökecektir. Bu nedenle, indüktör polaritesini değiştirecek ve çıkış kondansatörü üzerinden deşarj olacaktır (Mohan et al., 2003).



Şekil 3.6. Anahtar OFF (açık) olduğunda yükseltici tip DC-DC dönüştürücünün çalışması

İndüktör gerilimi artık giriş gerilimi ile seri haldedir ve kondansatör üzerindeki çıkış gerilimi **Şekil 3.6'**da gösterildiği gibi giriş ve indüktör gerilimlerinin toplamı olacaktır. Anahtarların sırası, istenen çıkış voltajını elde etmek için darbe genişlik modülasyonu şeması kullanılarak kontrol edilir (Santhoshi et al., 2022). Yükseltici dönüştürücünün çıkış gerilimi, kaynak ve indüktör gerilimlerinin toplamıdır, bu nedenle giriş geriliminden daha büyük olacaktır. Çıkış DC voltajının seviyesi indüktör, kapasitör, anahtarlama frekansı, dalgalanmalar ve modülasyon şemasının değerlerine bağlıdır. Yükseltici tip DC-DC dönüştürücünün iki çalışma modu vardır: sürekli ve süreksiz (Salado et al., 2021).

Sürekli modda, dönüştürücünün AÇIK ve KAPALI fazlarında sıfır endüktör akımı hiçbir zaman yaşanmaz. Süreksiz modda, endüktör akımı AÇIK ve KAPALI fazları sırasında sıfıra ulaşır. Denklem (3.5) ve (3.6), kararlı durum ve kayıpsız koşullar altında giriş ve çıkış gerilimleri arasındaki ilişkiyi tanımlar.

Sürekli Mod için:

$$V_o = \frac{1}{1-D} * V_i \quad (3.5)$$

Kesintili Mod için:

$$V_o = 1 + \frac{D^2 * T * V_i}{2 * L * I_o} \quad (3.6)$$

Denklem (3.5) ve (3.6)'da kullanılan değişkenler tanımları ile aşağıda verilmiştir.

$V_o$ : Çıkış gerilimi

$V_i$ : Giriş gerilimi

$I_o$ : Çıkış akımı.

D: Görev döngüsü

L: Endüktans

T: Zaman periyodu

### 3.1.2.3. Yükseltici tip DC-DC dönüştürücünün Tasarımı

Yükseltici tip DC-DC dönüştürücüdeki elektronik bileşenlerin tasarımı, uygulamaya geçmeden önce önemli bir adımdır. Bu çalışmada, yükseltici tip DC-DC dönüştürücü, solar PV dizisinden (250-280 V) giriş alacak ve bunu 800 V'a yükseltecek şekilde tasarlanmıştır. Yükseltici tip DC-DC dönüştürücünün bu yükseltilmiş voltajı (800 V) üç seviyeli inverterin girişi haline gelir. Bu nedenle, yükseltici tip DC-DC dönüştürücünün çıkışı veya eviricinin girişi DC bağlantı gerilimi olarak da adlandırılır.



Yükseltici tip DC-DC dönüştürücünün parametreleri, girişin 250 V ve çıkışın 800 V olduğu maksimum seviyede tasarlanmıştır. Yükseltici tip DC-DC dönüştürücünün tasarım parametreleri **Çizelge 3.2**'de listelenmiştir. Yükseltici tip DC-DC dönüştürücünün giriş-çıkış gerilimi ve giriş-çıkış akımı ilişkileri sırasıyla (3.5) ve (3.6)'nın değiştirilmiş formları olan (3.7) ve (3.8)'de tanımlanmıştır.

Görev döngüsü (D), anahtarlama sinyalinin iletim süresini belirleyen ve denklem (3.9)'da modellendiği gibi giriş gerilimine bağlı olarak çıkış gerilimini kontrol eden TON süresinin toplam süreye oranını ayarlayan önemli bir kontrol parametresidir.

**Çizelge 3.2.** Yükseltici tip DC-DC dönüştürücünün tasarım parametreleri

| Parametre                                                        | Formül                       | Değer                    |
|------------------------------------------------------------------|------------------------------|--------------------------|
| <b>Giriş Voltajı (Vi)</b>                                        | -                            | 250 V                    |
| <b>Çıkış Voltajı (Vo)</b>                                        | -                            | 800 V                    |
| <b>Anahtarlama Frekansı (f)</b>                                  | -                            | 5 kHz                    |
| <b>Yük Dayanımı (R)</b>                                          | -                            | 320 $\Omega$             |
| <b>Görev Döngüsü (D)</b>                                         | $D = (1 - V_i / V_o)$        | 0,65 – 0,68              |
| <b>Çıkış Akımı (Io)</b>                                          | $I_o = V_o / R$              | 2,5 A                    |
| <b>Giriş Akımı (Ii)</b>                                          | $I_i = I_o / (1 - D)$        | 7,14 A                   |
| <b>İndüktör Dalgalanma Akımı (<math>\Delta I_L</math>)</b>       | $\Delta I_L = 5 \% (I_o)$    | 0,357 A                  |
| <b>Kondansatör Dalgalanma Gerilimi (<math>\Delta V_C</math>)</b> | $\Delta V_C = 5 \% (V_o)$    | 40 V                     |
| <b>İndüktör (L)</b>                                              | $L = D V_i / f \Delta I_L$   | 95 $\approx$ 100 mH      |
| <b>Kondansatör (C)</b>                                           | $C = I_o D / f * \Delta V_C$ | 8.5 $\approx$ 10 $\mu$ F |

Şebekeye bağlı PV sistemleri için bir yükseltici tip DC-DC dönüştürücü tasarımında görev döngüsünün değeri, belirli sistem gereksinimlerine bağlıdır. Daha yüksek bir görev döngüsü daha düşük giriş gerilimlerini etkili bir şekilde kontrol ederken, daha düşük bir görev döngüsü daha yüksek giriş gerilimlerini kontrol eder. Seçilen görev döngüsü, hesaplanan endüktans ve kapasitans değerlerini etkiler. Verimli tasarım için en iyi seçim voltaj aralıkları, verimlilik, dönüşüm oranları ve bileşen talebini dikkate alır.

$$V_{dc} = \frac{V_{pv}}{(1 - D)} \quad (3.7)$$

$$I_o = I_i (1 - D) \quad (3.8)$$

$$D = T_{on} / T \quad (3.9)$$

Solar PV panelinin tahmini gücü 100 kW'tır. Giriş voltaj aralığı 250 V- 280 V'tur. Yükseltici tip DC-DC dönüştürücünün gerekli çıkış voltajı 800 V olarak seçilmiştir. Anahtarlar 5 kHz frekansında çalışır. Yukarıdaki tabloda belirtilen tüm bu hesaplanan değerler kullanılarak, indüktör ve kapasitörler sırasıyla denklem (3.10) ve (3.11) ile hesaplanır.

$$L = \frac{V_i * D}{f_{sw} * \Delta I} \quad (3.10)$$

$$C = \frac{I_o * D}{f_{sw} * \Delta V} \quad (3.11)$$


Yükseltici tip DC-DC dönüştürücünün tasarımında, giriş voltajına, amaçlanan çıkış voltajına ve izin verilen dalgalanma seviyesine bağlı olarak uygun görev döngüsünü, anahtarlama frekansını, indüktör ve kondansatör boyutunu seçmek önemlidir. Hesaplamalar, inverterin çalışma prensiplerinden türetilen bu parametreler arasındaki ilişkileri kullanır. Spesifikasyonlar tanımlandıktan sonra, verimli ve istikrarlı dönüşüm sağlayacak doğru bileşen değerlerini bulmak için formüller kullanılabilir. Tasarım süreci tamamlandıktan sonra MATLAB Simulink tabanlı simülasyon gerçekleştirilir. Halihazırda mevcut olan güneş enerjisinden en iyi şekilde yararlanmak için, sonraki kısımda son teknoloji MPPT tekniklerini kullanarak maksimum güç noktasını izleme stratejileri tartışılacaktır.

### 3.1.3. Maksimum Güç Noktası Takip Kontrolörü

İki aşamalı şebekeye bağlı bir PV sisteminde MPPT kullanımı, PV dizisinin çalışma noktasını sürekli olarak değiştirerek sistemin maksimum güneş enerjisi miktarını verimli bir şekilde yakalamasına izin verdiği için çok önemlidir (Suo et al., 2015). Değişen güneş ışınımı ve sıcaklık koşulları altında, bu dinamik optimizasyon optimum güç dönüşümü ve daha yüksek enerji üretimi sağlar. Bu, PV sistemin her zaman en verimli şekilde çalışmasını ve mümkün olan maksimum enerjiyi elde etmesini sağlar. **Şekil 3.7**'de MPPT'nin solar PV, bir yükseltici tip DC-DC dönüştürücü, bir inverter ve güç şebekesi ile birleştirilmiş genel blok diyagramı gösterilmektedir.


Bu tezde, önerilen MPPT kontrolörü stack LSTM ağ topolojisi kullanmış ve performansı FF-DNN ve P&O MPPT kontrolörleri ile karşılaştırılmıştır. **Bölüm 4**'te açıklanan önerilen LSTM tabanlı MPPT kontrolörünü sunmadan önce, bu bölüm en yeni MPPT kontrolörlerine odaklanmaktadır. Bu bağlamda, bu bölümde ilk olarak bir PV

hücresinin P-V ve I-V karakteristikleri, ardından T ve G değişiminin MPP üzerindeki etkisi ve ardından MPPT kontrolörü olarak geleneksel bir P&O, ANN ve RNN'nin çalışması açıklanmaktadır.



Şekil 3.7. MPPT'nin yükseltici tip DC-DC dönüştürücünün anahtarının görev döngüsünü kontrol etmesinin gösterilmesi

Şekil 3.8'deki güç-voltaj (P-V) eğrisi, değişken sıcaklık ve ışınlım koşulları altında bir PV hücresinin davranışını temsil etmektedir. PV karakteristiklerinde, açık devre gerilimi ( $V_{oc}$ ), kısa devre akımı ( $I_{sc}$ ) ve maksimum güç noktası (MPP) terimleri temel olarak kullanılır. Sıfır ön gerilimde, fotovoltaiik hücre, hücrenin maksimum akımı olan  $I_{sc}$ 'yi üretir. Gerilim sıfırdan pozitif doğru arttığında, hücrenin iç direncindeki artış nedeniyle akım azalmaya başlar ve gerilim  $V_o$  seviyesine ulaştığında akım sıfır olur.




Şekil 3.8. G ve T değerlerindeki değişimlerin PV dizisinin PV eğrisi üzerindeki etkisi

P-V veya I-V eğrisi üzerinde MPP olarak da bilinen, akım ve voltaj toplamının maksimumuna ulaştığı bir dirsek noktası vardır ve çıkış gücü bu noktada maksimumdur. T ve G gibi harici parametrelerdeki değişikliklere rağmen, MPPT kontrolörü PV sistemini bu MPP noktasında çalıştırmaya çalışır.

PV sistemlerin performansı T ve G parametrelerindeki değişimlerden etkilenir. Daha yüksek G değeri PV dizinin çıkış gücünü artırırken, daha yüksek T değeri PV dizinin çıkış gücünü azaltır. Bu nedenle, bu parametrelerin değişimleri göz önüne alındığında, PV dizisinin MPPT'sinin MPP'de çalışması gerekir. Bu nedenle, P&O, ANN'lar, RNN'ler ve diğer birçok teknik dahil olmak üzere dış parametrelerdeki değişikliklerle başa çıkmak için çeşitli ileri araştırma metodolojileri benimsenmiştir. Bu bölümde, tüm çalışma koşulları altında genelleştirilebilirliği artırmak için Bölüm 4'te açıklandığı gibi kısa süreli belleğe (LSTM) sahip stack bir mimari önermeden önce farklı stratejilerin avantajları ve dezavantajları değerlendirilmektedir. İlerleyen bölümlerde, son teknoloji MPPT stratejileri değerlendirilmektedir.

### 3.1.3.1. Değiştir ve Gözle (P&O) MPPT Kontrolörü


P&O yaklaşımı, PV panelden maksimum gücü elde etmek için iyi bilinen bir tepe tırmanma tekniğidir. En basit MPPT algoritmasıdır, tek voltaj sensörü kullanır, uygulaması basittir ve düşük güç uygulamaları için etkili kılan düşük matematiksel hesaplamalar sunar (Salman et al., 2018).



Şekil 3.9. PV eğrisi üzerinde MPP'yi çıkarmak için P&O yönteminin çalışma prensibi

Gerilim ve gücün mevcut ve önceki değerleri gereklidir. Bu şekilde P&O, PV eğrisi üzerindeki dirsek noktasına göre hareket yönüne karar verir ve ardından Şekil 3.9'da gösterildiği gibi doğru yöne doğru hareket eder. P&O MPPT tekniği, aşağıda açıklanan adımları izleyerek PV eğrisinde kullanılabilir.

1. Algoritma, PV eğrisi üzerinde MPPT noktasından daha düşük bilinen bir noktadan başlar.
2. PV sistemin voltajını veya akımını hafifçe değiştirir.
3. Yeni değiştirilmiş voltaj veya akımdaki gücü belirler.
4. Güç öncekinden yüksekse, algoritma yeni voltaj veya akıma geçer.
5. Güç çıkışı önceki güç çıkışından daha azsa, algoritma önceki voltaj veya akıma geri döner.
6. Algoritma MPP'ye ulaşana kadar 2'den 5'e kadar olan adımları iteratif olarak tekrarlar.



Şekil 3.10. P&O MPPT kontrolörünün akış şeması ve örnek MATLAB kodu

**Şekil 3.10**, P&O tabanlı MPPT algoritmasının akış şemasını, buna karşılık gelen MATLAB simülasyon kodunu göstermekte ve solar PV sisteminin fotovoltaiik MPP'sini keşfetmek ve optimize etmek için gereken sıralı adımları ortaya koymaktadır. P&O MPPT algoritması basit, ucuz ve güvenilir olma avantajlarına sahiptir, ancak gecikmeli yakınsamadan etkilenecektir ve ayrıca gürültüye duyarlıdır. MPP'yi izlemek için P&O algoritması gerilime değiştirici yönde etki eder ve güç değişimini ölçer ancak tam MPP tepe noktasına ne zaman ulaşıldığını belirleyemez. Tepe noktasına ulaşıldığında, pertürbasyonlar yön değiştirerek negatif güç tarafına yol açar ve MPP etrafında salınmaya başlar. Güç gözlemlerinin aşırı basitleştirilmesi, bir işlemi MPP tepe noktasına yaklaştıran veya uzaklaştıran pertürbasyonlar arasında ayırım yapmayı zorlaştırır.

Ayrıca, çalışma koşullarındaki hızlı değişiklikler güç salınımlarına yol açar (Femia et al., 2009). Daha küçük pertürbasyon adımları salınım büyüklüğünü azaltırken MPP izleme hızını yavaşlatır. Sonuç olarak, P&O MPPT'de izleme performansı ve salınımlar azalır.

### 3.1.3.2. Yapay Sinir Ağı (ANN) MPPT Kontrolörü


İlk basit sinir modeli 1943 yılında matematikçiler tarafından geliştirilmiştir. 1980 yılında, işlem gücü ve öğrenme yöntemlerindeki gelişmeler ANN'ların üstünlüğü yeniden ele geçirmesini sağlamış ve 2012 yılında bir görüntü tanıma yarışmasında insanları geride bırakarak doğrusal olmayan verileri işleme yeteneklerini göstermişlerdir. ANN'lar biyolojik sinirlerden ve nöronlar gibi düğümlerin birbirine bağlanmasından esinlenmiştir; ANN'lar ve beyin arasındaki benzerlik, bilgiyi aynı anda öğrenme, genelleme, soyutlama ve işleme yetenekleridir (Fine, 2005).

ANN tabanlı MPPT algoritması, P&O, IC ve FLC gibi geleneksel tekniklerin eksikliklerinin üstesinden gelmek için tanıtılmıştır (Senthilkumar et al., 2023). Bu bölüm, sinir ağlarının teorik temellerinin, MPPT alanına uygulamalarının ve karmaşık sistemlerde uygulanmalarının ayrıntılı bir analizini sunmaktadır. Bu ağlar, ileri beslemeli ve geri beslemeli yapılar da dahil olmak üzere çeşitli topolojilere sahiptir. İleri beslemeli mimarinin, güneş pillerinin doğrusal olmayan özelliklerini yakalamada özellikle etkili olduğu kanıtlanmıştır. İleri beslemeli varyantlar arasındaki çok katmanlı yapılandırma, gizli katmanlar içindeki karmaşık ağırlıkları hesaplama kabiliyeti nedeniyle yaygın olarak övülmektedir (Sharkawy et al., 2023). Bu, MPPT bağlamında doğru modelleme sağlar.

ANN tabanlı MPPT algoritmasına geçmeden önce, bu bölümde ilk olarak ANN'nın temel yapı taşı olan "tek nöron modeli" açıklanmaktadır.

### 3.1.3.2.1. Tek Nöronlu Algılayıcı Modeli

Tek bir nöron, "perceptron" olarak da bilinen sinir ağının en küçük bileşeni ve yapı taşıdır. Bir sinir ağı, bilgiyi eşzamanlı olarak işleyen çok sayıda bireysel nörondan oluşur. Bir ağ, aldığı girdiye ve üzerinde eğitildiği hedeflere dayalı olarak bir çıktıyı tahmin etmek için kullanılan nöronlar arasındaki bağlantılar tarafından oluşturulur (Hagan et al., 2002). Nöronun öğrenme sürecini iyileştirmek için, nöronlar arasındaki her bir bağlantıya atanan ağırlıklar optimizasyon algoritmaları kullanılarak güncellenir. Ağırlık güncellemeleri için yaygın olarak kullanılan optimizasyon algoritmaları stokastik gradyan iyi (SGD), geri yayılım (BP), uyarlanabilir moment tahmini (Adam) ve momentumdur ("Res. Anthol. Artif. Neural Netw. Appl.," 2021).



Şekil 3.11. Tek bir nöronun temel yapısı

Adam optimizier, SGD ve momentumun birleşimidir ve gelişmiş performansı, ANN uygulamalarını tahmin, öngörü, konuşma tanıma, bilgisayar görüşü, tanımlama, sınıflandırma ve robotik otomasyon gibi çeşitli alanlarda daha da çeşitlendirmiştir (Gu et al., 2018). ANN, temel yapı taşları olarak yapay nöronlardan oluşur ve tek bir nöronun yapısı Şekil 3.11'de gösterilmiştir.

Bir nöronun yapısında, girdi değerlerinin ağırlıklı bir toplamını ve aktivasyon fonksiyonunu kaydıran ve girdi/çıkı ofsetlerinin modellenmesini sağlayan ek bir bias

terimini kabul eder. Çıktı değeri daha sonra ağırlıklı girdilerin ve biasın bir aktivasyon fonksiyonundan geçirilmesiyle oluşturulur (Heaton, 2012). Girdiler, bias ofseti ve çıktı arasındaki karmaşık etkileşim doğrusal olmayan aktivasyon fonksiyonu tarafından çıkarılır. ANN'nın bir dizi girdi değeri için uygun çıktı değerlerini aldığı denetimli eğitim aşamasında, yapay nöronların ağırlıkları ve biasları öğrenilir. Bir ANN, eğitimin karmaşıklığını tam olarak yansıtan doğru çıktı değerleri üretene kadar nöronlarının ağırlıklarını ve önyargılarını yinelemeli olarak ayarlar. MPPT kontrolörü olarak tek bir nöronun temel bileşenleri aşağıda listelenmiştir:

- **Girdi:** Yapay nöron, zaman serisi verilerine ait iki girdi (sıcaklık ve ışıınım) alır.
- **Ağırlık:** Nörona yapılan her girdiye, girdinin nöronun çıktısını ne kadar etkilediğini belirleyen bir ağırlık verilir.
- **Yanlılık:** Aktivasyon fonksiyonuna geçmeden önce girdilerin ağırlıklı toplamına eklenen bir girdidir. Gerçek çıktıdan en az farka sahip nöronun çıktısını oluşturmak için aktivasyon fonksiyonunu sağa veya sola kaydırmaya yardımcı olur.
- **Aktivasyon Fonksiyonu:** Bias ile birlikte girdilerin ağırlıklı toplamı, nihai çıktıyı üretmek için doğrusal olmayan dönüşüm uygulayan aktivasyon fonksiyonundan geçer.
- **Çıktı:** Yapay nöronun çıktısı, aktivasyon fonksiyonundan gerçekleştirilir. Ağırlıklar, sapma ve aktivasyon işlevi, gerçek çıktıya yakın nihai çıktıyı tahmin etmede önemli bir rol oynar.

Sinir ağlarında, tahmin veya kestirim doğruluğu büyük ölçüde optimizasyon algoritmasının ve aktivasyon fonksiyonunun seçimine bağlıdır (C. S. Chen et al., 2022). Doğrusal veya doğrusal olmayan aktivasyon fonksiyonunun seçimi, girdi verilerinin türüne dayanmaktadır. Sinir ağlarında kullanılan popüler aktivasyon fonksiyonları, sırasıyla (3.12) ila (3.15) denklemlerinde modellendiği gibi sigmoid aktivasyon fonksiyonu, ReLU, Tanh ve SoftMax aktivasyon fonksiyonlarını içerir.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.12)$$

$$f(x) = \max(0, x) \quad (3.13)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.14)$$

$$\sigma(x_i) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad (3.15)$$



Aktivasyon fonksiyonlarının seçimi, girdinin doğasına ve kullanım amacına göre seçilir ve sinir ağının performansını belirlemede çok önemlidir. Bir girdiyi  $[0, 1]$  aralığına eşleyen Sigmoid fonksiyonu, olasılıksal gösterimiyle ikili sınıflandırma görevlerinde kullanım alanı bulur. ReLU, özellikle zaman serileri ile çalışırken negatif değerleri sıfırlayarak çeşitli veri formatları için kullanışlıdır.  $[-1, 1]$  aralığını kapsayan Tanh, sıfır merkezli veriler için uygundur. Girdileri olasılıklara dönüştüren Softmax, verileri birden fazla sınıfa sınıflandırmak için etkilidir. Çeşitli veri ayarları altında ağ performansını optimize etmek için, bu işlevler doğrusal olmama ve uyarlanabilirlik içerir.

Bu bölümde, son teknoloji ürünü Maksimum Güç Noktası İzleme (MPPT) kontrolörü olarak "ANN" terimi tanıtılmaktadır. Tez, alternatif bir MPPT kontrolörü olarak bir Derin Öğrenme (DL) modeli, özellikle de stack LSTM önermektedir. Kapsamlı bir karşılaştırmayı kolaylaştırmak için çalışmada, ek bir gizli katmana sahip ileri beslemeli bir mimari ile karakterize edilen derin bir Yapay Sinir Ağı (ANN) kullanılmıştır. Bu derin ANN, **Bölüm 5**'te ayrıntılı olarak tartışılan önerilen stack LSTM modeline benzeyen karmaşıklığı nedeniyle seçilmiştir.

#### 3.1.3.2.2. MPPT Kontrolörü Olarak ANN (FF-DNN) Simülasyonu

Bu alt bölümde, Simulink MATLAB©, 100 kW güçte şebekeye bağlı bir PV sistemi için FF-DNN tabanlı bir MPPT'yi simüle etmek için kullanılmıştır. SunPower TS-SPR-308E dizisi (250-280 V) üretir ve bunu yükseltici tip DC-DC dönüştürücüye besler ve MPPT kontrolörü, yükseltici tip DC-DC dönüştürücüdeki anahtarların görev döngüsünü ayarlayarak yükseltici tip DC-DC dönüştürücünün çıkışı olan 800 V'taki DC bağlantı voltajını düzenlemek için kullanılır. FF-DNN modelinin parametreleri ilerleyen alt bölümde daha ayrıntılı olarak açıklanmaktadır (ayrıca bkz. Bölüm 5). Eğitim ve test amaçları için dikkate alınan ortak adımlar arasında (a) Veri Toplama ve Ön İşleme, (b) Ağ Seçimi, (c) Ağ Eğitimi ve (d) Ağ Testi yer almaktadır. Alt bölüm ayrıca her bir adımın açıklaması ile devam etmektedir.

- **Veri Toplama ve Ön İşleme**

Bir ANN (FF-DNN) geliştirmenin ilk adımı girdi ve çıktı verilerini toplamaktır. Daha büyük bir veri kümesi ANN'nın performansını artırır. Bu çalışmada, G ve T'den gelen giriş verileri (3.16) ve (3.17) kullanılarak toplanırken, hedef veriler (3.18)

kullanılarak toplanmıştır. Değişken hava koşullarının varlığında, girdi ve hedef veriler toplanır, veriler ön işleme tabi tutulur ve ortalama ve birim varyans ile standartlaştırılır. Önceden işlenmiş ve standartlaştırılmış veriler daha sonra denetimli öğrenmede öğrenme yöntemini seçmek için kullanılır.

$$G = [(G_{max} - G_{min}) \times rand] + G_{min} \quad (3.16)$$

$$T = [(T_{max} - T_{min}) \times rand] + T_{min} \quad (3.17)$$

$$V_{mp} = V_{mp(STC)} + \beta(K * T - T_s) + \alpha(1 + G) \quad (3.18)$$


- **ANN (FF-DNN)'nın Ağ Tasarımı**

Katman sayısı, gizli nöronlar ve aktivasyon fonksiyonu dahil olmak üzere sinir ağı türünün seçimi, söz konusu görevin türüne, veri kümesinin boyutuna ve mevcut işlem gücüne bağlıdır (Jin et al., 2022). Simulink MATLAB©, sinir ağları oluşturmak ve eğitmek için otomasyon sunan kullanıcı dostu bir arayüz sağlar. Benzer şekilde, python, tahmin ve öngörü görevlerini gerçekleştirmek için veri kümesini toplamak, ön işleme tabi tutmak, eğitmek ve test etmek için kullanılacak TensorFlow, PyTorch, Keras ve numpy gibi ünlü kütüphanelere sahiptir. Tasarım sürecinde, tıpkı önerilen stack LSTM gibi, aslında bir DNN modeli olan iki katmanlı bir NN, ilk katmanda 64 gizli birim ve ikinci gizli katmanda 32 gizli birim ile ele alınmış, zaman serisi sıralı verilerimize en iyi uyan ReLU aktivasyon fonksiyonu kullanılmış ve eğitim verileri için tahminler ile gerçek çıktılar arasındaki farkı en aza indiren "Adam" optimizatörü kullanılmış, NN'nin ağırlıkları ve yanlılıkları eğitim sürecinde değiştirilmiştir.

- **ANN'nin Eğitimi (FF-DNN)**

ANN veya DNN'nin eğitimi, belirli bir girdi kümesi için bir çıktıyı kesin olarak tahmin edebilen bir model oluşturmak için gereklidir. NN, veri içindeki örüntüleri ve ilişkileri keşfetmek ve bu öğrenmeyi görülmeyen verilere genellemek için bir veri koleksiyonu üzerinde eğitilir. Eğitim verileri için tahminler ve gerçek çıktılar arasındaki farkı en aza indirmek için, NN'nin ağırlıkları ve bias değerleri eğitim süreci sırasında değiştirilir. Ağırlıkları ve biasları iteratif olarak güncellemek için kullanılan "Adam" optimizasyon teknikleri ve benzer optimize edici, yazarlar tarafından hastalık tahmini için (C. S. Chen et al., 2022)'de kullanılmıştır. Yeni, görülmemiş verileri doğru bir şekilde

tahmin etmek veya sınıflandırmak için, bir sinir ağının girdi verilerindeki örüntüleri tespit etmek üzere eğitilmesi gerekir. LSTM ağı, girdiler (G, T) ve hedef (Vmp) ile eğitilir.



Şekil 3.12. Tüm ANN, ML ve DL ağlarının çalışma sürecini temsil eden akış şeması

PV dizinin her biri 1 milyon (1.000.000) veri noktasından (gözlem) oluşmaktadır ve bunlar 4. ve 5. bölümlerde ayrıntılı olarak açıklanmıştır. Başlangıçtan itibaren, toplam veri kümesinin %80'i eğitim için kullanılmış ve sona kalan %20'lik kısım ise yazarlar tarafından önerildiği gibi test ve doğrulama için kullanılmıştır (Korkmaz & Acikgoz, 2022). ANN'nın eğitim sürecindeki adımlar Şekil 3.12'teki akış şemasında gösterilmektedir.

- **ANN'nın (DNN) Test Edilmesi**

Bir sinir ağı sisteminin bir uygulamada kullanılabilmesi için önce test edilmesi gerekir. Test süreci, tipik olarak mevcut tüm verilerin %20'si olan görünmeyen verileri içerir (Korkmaz & Acikgoz, 2022). Modelin test seti üzerindeki performansını değerlendirmek için geri çağırma, kesinlik, doğruluk ve F1 puanı gibi ölçütler kullanılır. Ağ tasarımı bölümünde açıklandığı gibi, hata oranı belirli bir eşiği aştığında, hiper parametreler, mimari, eğitim verileri ve diğer faktörler değiştirilerek model yeniden eğitilmelidir. Aşırı ezberden kaçınmak için modelin doğru şekilde genelleştirilmesini sağlamak önemlidir. Testler, modelin pratik kullanım için sağlam ve güvenilir olduğunu doğrulamaktadır.

- **Performans Metrikler**

ANN (DNN) ağının performansı, Ortalama Kare Hata (MSE), Ortalama Kare Hatanın Kökü (RMSE), Hareketli Ortalama Hata (MAE) ve doğrulama kaybı gibi performans endekslerine göre test edilir. Tüm performans parametrelerinin matematiksel formu denklem (3.19) ila (3.22)'de modellenmiştir. Benzer metrikler yazarlar tarafından (Salam et al., 2015)'te ele alınmıştır. Yukarıdaki denklemlerde, N 1.000.000 net veri örneğini,  $V_{mp}$  gerçek çıktı veya hedef değeri ve  $\hat{V}_{mp}$  LSTM modelinden tahmin edilen veya izlenen çıktı veya hedef değeri temsil etmektedir.

$$MSE = \frac{1}{N} \sum_{i=1}^n (V_{mp} - \hat{V}_{mp}) \quad (3.19)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (V_{mp} - \hat{V}_{mp})^2} \quad (3.20)$$

$$MAE = \frac{1}{N} \sum_{i=1}^n |V_{mp} - \hat{V}_{mp}| \quad (3.21)$$


$$\text{Validation Loss} = \frac{1}{2} \left( \frac{1}{N} \sum_{i=1}^n (V_{mp} - \hat{V}_{mp}) \right) \quad (3.22)$$

Zaman serisi tahmin uygulamaları bağlamında, ileri beslemeli ANN veya DNN'nin performans değerlendirmesi, modelin doğruluğunu ve etkinliğini

değerlendirmek için çok önemlidir. Model, test seti üzerindeki performansı tatmin edici olana kadar hizmete sokulmamalıdır.

### 3.1.3.3. Tekrarlayan Sinir Ağı (RNN) MPPT Kontrolörü

Tekrarlayan sinir ağları (RNN'ler), sıralı veriler aracılığıyla geçmiş veya tarihsel bilgileri depolamak için tasarlanmış özel bir sinir ağı türüdür (Tsantekidis et al., 2022). RNN'ler dinamik zamansal aktivite sergileyebilir çünkü benzersiz aktivasyon fonksiyonlarına ve kendi kendine döngülü bağlantılara sahip tekrarlayan nöronlara sahiptirler. Tekrarlayan topoloji nedeniyle, RNN'ler dizinin önceki girdileri hakkında bilgi depolamak için dahili belleğe sahiptir. Farklı yapıları nedeniyle, RNN'ler sıralı verileri daha iyi işleyebilir ve önceki girdileri hatırlayabilir ve bunları gelecekteki çıktıları tahmin etmek için kullanabilir, bu nedenle RNN'ler zaman serisi tahmini için FFNN'lere daha iyi bir alternatiftir (Mohammad & Musa, 2022). RNN'nin blok diyagramı Şekil 3.13'te sunulmuştur.



Şekil 3.13. Bir RNN'nin yapısı ve katlanmamış açıklaması

Bir RNN, giriş verilerini birbirine bağlı bloklardan oluşan bir ağ aracılığıyla sırayla işleyerek çalışır. Her zaman adımında RNN, giriş verilerine ve önceki gizli duruma dayalı olarak belirli ağırlıkları kullanarak mevcut gizli durumu hesaplar. Bu gizli durum, ağın önceki zaman adımlarından gelen verileri tutarak döngüsel kalıpları tanımasını sağlar.

Belirli bir zaman adımının çıktısı mevcut gizli duruma göre oluşturulur. Çıktının bir sonraki zaman adımının girdisi olmasına neden olan döngü, RNN'nin verilerin zamansal bağımlılıklarını öğrenmesini ve hatırlamasını sağlar. Sekans boyunca tekrar

eden bu yinelemeli süreç sayesinde RNN'ler sekansları ve zamansal bağımlılıkları başarılı bir şekilde modelleyebilir (Mohammad & Musa, 2022). Mevcut durum, giriş verilerinin, önceki gizli durumun ve (3.23)'te modellendiği gibi durumu güncellemek için ilişkili ağırlıkların ve aktivasyon fonksiyonunun kombinasyonudur. Tanh aktivasyon fonksiyonu uygulandıktan sonra güncellenmiş denklem (3.24)'te belirtilmiştir. Mevcut gizli duruma veya son gizli duruma bağlı olarak, RNN çıkış katmanı (3.25)'te modellendiği gibi bir tahmin veya nihai çıktı üretir.

$$h_t = f(W X_t, U h_{t-1}) \quad (3.23)$$

$$h_t = \tanh(W X_t, U h_{t-1}) \quad (3.24)$$

$$Y_t = \tanh(W_o h_t + b_o) \quad (3.25)$$

Hem RNN hem de FFNN (tek katmanlı ve DNN) geri yayılım tabanlı öğrenme kullanır, ancak RNN tekrarlayan topolojisi ve kısa süreli belleği nedeniyle dizileri modellemede daha iyidir (Mohammad & Musa, 2022). Bu, ısıtım gibi hava değişkenlerindeki değişiklikler nedeniyle fotovoltaiik sistemlerin MPPT kontrolünde çok önemli olan zamansal dinamikleri ele almalarına olanak tanır. RNN'ler, FFNN'lerin aksine, bu tür zamansal kalıpları öğrenebilir ve bu da onları MPPT kontrolörleri için uygun hale getirir.

Farklı topolojilere sahip olmalarına rağmen, RNN'ler ve FFNN'ler veri hazırlama, eğitim stratejileri ve performans değerlendirmesi açısından önemli benzerlikler göstermektedir. Her iki model de veri hazırlama, temizleme ve eğitim, doğrulama ve test kümelerine ayırma gerektirir. Vektörler ve diziler uygun şekilde normalleştirilmeli ve dönüştürülmelidir. Her iki model de eğitim aşamasında kayıp gradyanlarını hesaplar ve ağırlıkları geri yayılıma göre ayarlar. Toplu öğrenme, düzenlileştirme, optimizasyon teknikleri ve MSE gibi kayıp ölçümlerinin tümü benzerdir. Her iki ağ da deneyimsiz verilerdeki performansı değerlendirmek için doğruluk, doğruluk/geri çağırma ve F1 puanı ölçümleri kullanılarak test edildi. Aynı temel denetimli öğrenme ilkeleri, mimariden bağımsız olarak, ileri beslemeli veya tekrarlı olarak geçerlidir.

Seçilen topolojiler veri işleme açısından farklılık gösterir: FFNN statik vektörler kullanırken, RNN sıralı dizilere dayanır. FFNN'lerin aksine, RNN'ler eğitim sırasında zamansal bir korelasyon sergiler. Değerlendirme yöntemleri de farklıdır: RNN'ler sıralı çıkarım gerektirirken, FFNN'ler genellikle daha fazla veri ve farklı örnek boyutları gerektirir. Her ikisi de kaybolan gradyanlar sorunuyla karşı karşıyadır ve RNN'ler uzun

vadeli ilişkilere dayandıkları için daha hassastırlar. Yinelemeli RNN mimarileri, özel veriler ve eğitim ayarlamaları olmadan dinamik modeller oluşturmakta zorluk çekebilir.

#### 3.1.3.4. LSTM Ağıının kapsamı

Temel RNN, küçük ağırlıkların sürekli yayılımında uzun kaybolan ve patlayan gradyan serileri sergiler. Bu nedenle, uzun vadeli bağlantıları öğrenmek ve bilgileri uzun vadeli bellekte saklamak zordur. Bu nedenle, LSTM bilgi akışını dikkatlice kısıtlayan ve bu sorunları ele alan bir geçit mekanizması içerir (Mohammad & Musa, 2022). Giriş, çıkış ve unutma kapıları, hangi bilgilerin saklanacağına ve hangilerinin silineceğine karar vermek için seçici güncellemeler kullanır. Gradyanların korunması ve uzun vadeli bağımlılıkların yakalanması, karmaşık zaman serisi tahmin görevleri için çok önemlidir. RNN'lerin temel sınırlamalarının ötesine geçen özel olarak tasarlanmış bir LSTM geçit mimarisi, uzun dizilerin verimli bir şekilde modellenmesini sağlar.

Önerilen LSTM tabanlı stack MPPT kontrolörü, **Bölüm 4**, "Önerilen Araştırma Metodolojisi"nde ayrıntılı olarak açıklanan bu tezin hedeflerini yerine getirmektedir. DNN dahil en son MPPT algoritmalarının ve önerilen LSTM tabanlı MPPT kontrolörünün sonuçları **Bölüm 5**'in "Sonuçlar ve Tartışma" bölümünde sunulmuştur. Bölümün bu noktasına kadar, önerilen şebekeye bağlı PV sisteminin ilk aşaması açıklanmıştır ve önerilen çalışmanın ikinci aşamasına, yani şebekeye bağlı evirici kontrol aşamasına geçilmektedir.

### 3.2. Şebeke Bağlantılı PV Sisteminin İkinci Aşaması

Bu bölüm, şebekeye bağlı PV sistemler için evirici tasarımı ve kontrol stratejilerini ele alan şebekeye bağlı PV sistemin ikinci aşamasına dayanmaktadır. Şebeke entegrasyonunda eviricilerin rolüne ve şebeke entegrasyonu için solar PV dizisinin doğru akımının alternatif akıma verimli bir şekilde dönüştürülmesine özel önem verilmektedir. İşlenen konular arasında PWM yöntemleri, kontrol topolojileri (senkron döner çerçeve, PR kontrolörlü sabit çerçeve, PI kontrolörlü doğal çerçeve), evirici tasarımı ve NPC eviriciler gibi daha gelişmiş seçenekler yer almaktadır. Şebeke zorlukları, PLL, gerilim kaynaklı inverter kontrolü, PWM, filtreler ve çıkış filtresi tasarımı da incelenmektedir. İnverter tasarımı ve kontrolü, şebekeye bağlı PV sistemlerin güç aktarımını en üst düzeye çıkarma ve güç kalitesini iyileştirme becerisinde önemli faktörler olarak





(c) şebeke gerilimi ve frekans senkronizasyonunun sağlanması gibi aşağıdaki faktörlere bağlıdır. İnverterin ana görevleri aşağıda listelenmiştir:

- Şebekeye verilen aktif gücün kontrolü.
- DC bağlantı voltaj regülasyonu.
- Şebekeye yüksek kalitede güç enjeksiyonunun sağlanması
- Şebeke senkronizasyonu.

### 3.2.2. İnverter Kontrol Topolojileri


Şebekeye entegre PV sistemlerde, ana inverter kategorileri transformatörüz, tek kademeli, çok kademeli ve mikro inverter topolojileridir. İnverter kategorisinin seçimi, söz konusu PV sisteminin boyutuna, istenen verimliliğe ve kurulum maliyetlerine bağlıdır.

**Çizelge 3.3.** Şebekeye Bağlı PV Sistemler için inverter topolojilerinin karşılaştırmalı analizi

| Topoloji         | Avantajları                                                             | Dezavantajları                                        |
|------------------|-------------------------------------------------------------------------|-------------------------------------------------------|
| <b>NPC</b>       | Daha yüksek güç seviyelerinde çalışma<br>Geliştirilmiş harmonikler      | Daha yüksek karmaşıklık                               |
| <b>H5 Serisi</b> | Basit Uygulama<br>Daha düşük maliyet                                    | Daha düşük verimlilik<br>Daha yüksek harmonik bozulma |
| <b>HERİK</b>     | H5 ve NPC'nin melezi<br>Her ikisinin de avantajlarından birkaçını sunar | H5'ten daha karmaşık                                  |
| <b>H6 Serisi</b> | NPC'den daha basit<br>Daha az harmonikle iyi verimlilik                 | NPC kadar verimli değil                               |

Akıllı inverterler mükemmel performans, uzun kullanım ömrü ve düşük üretim maliyetleri sunar. Silikon teknolojisi ile üretilen inverterlerin verimliliği %94 ila 96 arasında değişmektedir ve güçleri ve verimlilikleri seçilen topolojiye bağlıdır (Mirafzal & Adib, 2020). Bir topoloji seçerken, maliyet, işlenebilirlik ve yalıtım ve dönüşüm aşamalarının sayısı gibi sistem gereksinimleri dikkate alınmalıdır. İnverter topolojilerinin karşılaştırmalı analizi **Çizelge 3.3'**te listelenmiştir.

Transformatörsüz, iki aşamalı, tek aşamalı ve diğer tasarımlar arasındaki farkları anlamak, belirli bir PV kurulumu için en iyi seçeneği belirlemeyi kolaylaştırır. Bu nedenle, bu bölümde her bir topolojinin ayrıntılı bir açıklaması ele alınmaktadır. Verilen inverter topolojilerinin blok diyagramı **Şekil 3.15'**te sunulmuştur (Blaabjerg et al., 2006).



Şekil 3.15. Literatürde kullanılan inverter topolojileri

### 3.2.2.1. Transformatörsüz İnverterler

Transformatörsüz dönüştürücüler, büyük düşük frekanslı transformatörlere olan ihtiyacı ortadan kaldırarak verimliliği artırabilen, boyutu ve ağırlığı azaltabilen ve maliyeti düşürebilen gelişmiş bir güç dönüştürme teknolojisidir (P & J, 2021). Bu dönüştürücülerde transformatör bulunmaması, transformatörlerdeki bakır kayıplarını ortadan kaldırdığı için önemli avantajlara sahiptir. Şebekeden galvanik olarak izole edilmediklerine dikkat etmek önemlidir.

NPC, H5, H6 ve HERIC gibi çeşitli yaygın transformatörsüz inverter topolojileri, yazarlar tarafından vurgulandığı gibi şebekeye bağlı PV sistemlerinde yaygın olarak kullanılmaktadır (Khan et al., 2020). Örneğin, NPC topolojisinde, nötr nokta DC'ye bağlanır, bu da anahtar voltajını telafi edebilir ve gücü artırmaya yardımcı olabilir (Rodriguez et al., 2010). H5 topolojisinde, köprü anahtarında tek kutuplu modülasyon kullanılır ve bu da verimliliği artırır. HERIC topolojisi ise hem H-köprüsü tasarımının hem de NPC'nin avantajlarını bir araya getirmektedir (Zeb et al., 2018). Kaçak akım sorunları, dikkatli yerleşim tasarımı ve topraklama prosedürleri ile etkili bir şekilde ele alınabilir.

Özetle, transformatörsüz inverterler, gelişmiş güç dönüşüm verimliliği, daha küçük alan gereksinimleri ve daha düşük maliyetler dahil olmak üzere çeşitli avantajlar sunar.

### 3.2.2.2. Çok Aşamalı İnverterler

Çok kademeli inverterler, güç kalitesini, kontrol doğruluğunu ve voltaj kazancını iyileştirmek için birden fazla güç dönüştürme aşaması kullanan gelişmiş güç elektroniği cihazlarıdır (Rajkumar & Rathinam, 2023). Çok aşamalı inverterler, birden fazla dönüştürme işlemini tek bir cihazda birleştirerek tek aşamalı inverterlerden daha iyi performans gösterir. İlk aşama DC-DC inverterler genellikle güneş enerjisinden verimli bir şekilde güç elde etmek ve maksimum güç noktasını belirlemek için kullanılır. Şebeke entegrasyonu, PV dizisinin doğru akımını senkron alternatif akıma dönüştüren bu inverterlerin ikinci aşaması tarafından sağlanır. Çok aşamalı inverterlere, doğaları gereği karmaşık olmaları nedeniyle daha karmaşık kontrol stratejileri gerektirir, ancak sistemin performansını artırır (Khan et al., 2020).

### 3.2.2.3. Modül Entegre İnverterler

Modüle entegre inverterlere, inverter ve PV modülünü sorunsuz bir şekilde tek bir "AC modülünde" birleştirir ve devrim niteliğinde bir yaklaşım örneğidir (Zhang et al., 2018). Bu fikrin kapsamı, sistemin yaşam döngüsü boyunca çeşitli avantajlar sunan güç üretimi ve dönüşümünün tek bir üniteye birleştirilmesinden oluşmaktadır. Ana avantajlardan biri, entegre modüllerin gerçek "tak ve çalıştır" işlevselliği sayesinde basitleştirilmiş sistem tasarımı ve kurulum prosedürleridir. Bu inverterlere, harici İnverterlere olan ihtiyacı azaltarak verimli inverter-PV ölçeklendirmesi sağlar. Ayrıca modüller arasındaki uyumsuzluk kayıplarını azaltarak sistem verimliliğini de artırır (Islam et al., 2015). Ancak bu yaklaşımın her bir modül için watt başına daha yüksek fiyatlara yol açabileceğine dikkat etmek önemlidir. Esneklik ve uyarlanabilirlik sunan mikro inverterler, modül entegre sistemler dünyasında çoğalmıştır. Modül entegre inverterler, güç üretimi ve dönüşümünü sorunsuz bir şekilde birleştirdikleri, kurulum prosedürlerini basitleştirdikleri ve özelleştirilmiş inverter entegrasyonu yoluyla sistem performansını artırdıkları için kapsamlı bir çözüm sunmaktadır.

### 3.2.2.4. Kaskat H Köprü İnverter

Kaskat H-köprüsü tasarımı, birkaç tam köprü inverter modülünün sıralı bağlantısını içeren bir başka gelişmiş güç elektroniği topolojisidir (Ramasamy et al.,

2022). Kapsamı, daha düşük harmonik içeriğe sahip çok seviyeli, merdiven basamaklı bir çıkış dalga formu üretmek için bu bağımsız modüllerin her birini kullanmayı ve güç dönüştürme uygulamaları için çeşitli faydaları içerir. Kademeli konfigürasyondaki her bir H-köprüsü modülünün çıkışı bir kare dalgadır. Bununla birlikte, kademelendirmenin yarattığı sinerji, daha az harmoniğe sahip çok katmanlı bir dalga şeklinin üretilmesini sağlayarak orta gerilim şebekelerine entegrasyonu kolaylaştırır (Yaosuo Xue et al., 2004). Bu topolojinin önemli bir avantajı, daha yüksek güç gereksinimlerini karşılamak için daha fazla H-köprüsünün dahil edilmesine olanak tanıyan modüler ve ölçeklenebilir tasarımıdır. Sonuç olarak, kademeli H-köprüsü şeması, tam köprü inverter modüllerini birleştirerek, harmonikleri etkili bir şekilde azaltarak ve şebeke entegrasyon yeteneklerini artırarak çok seviyeli sinyaller üretmek için sofistike bir yöntem sunar. Bu şemanın birçok güç dönüşüm ortamındaki popülerliği büyük ölçüde uyarlanabilirliği ve ölçeklenebilirliğinden kaynaklanmaktadır.


### 3.2.3. İnverter Kontrol Mimarileri (İnverter Çeşitleri)

İki tür şebekeye bağlı PV inverter topolojisi vardır: gerilim kaynaklı inverterler (VSI) ve akım kaynaklı inverterler (CSI). Gerilim kaynaklı inverterlere, aktif gücü ve gerilimi bağımsız olarak kontrol edebildikleri için şebekeye bağlı PV sistemlerde genellikle tercih edilir. Ancak bu iki inverter arasında seçim yaparken güç faktörü kontrolü, verimlilik ve harmonik yönetimi gibi sistem gereksinimleri göz önünde bulundurulmalıdır (Sahan et al., 2011). Her bir topoloji daha sonra ayrıntılı olarak açıklanmaktadır.

#### 3.2.3.1. Gerilim Kaynaklı İnverter

VSI, gelişmiş çalışma metodolojisi ile karakterize edilen şebekeye bağlı PV sistemlerinin önemli bir bileşenidir. VSI, devresine neredeyse sabit bir DC girişi sağlamak ve sonraki işlem için zemini hazırlamak için birkaç paralel kapasitör kullanır (Chang et al., 2022). İnverterin esnek çalışmasının önemli bir unsuru, kontrollü anahtarlama yoluyla değişen darbe genişliklerine sahip alternatif bir çıkış voltajı dalga formunun üretilmesidir. Gerilimin harmonik içeriğini azaltmak için bu darbe dizisinde şebeke tarafında bir LCL filtreleme cihazı gereklidir (GHOSHAL & JOHN, 2015). VSI'lar hem gerilim hem de akım kontrol modlarında iyi performans gösterir. Gerilim

kontrol modunda VSI, çıkış gerilimini şebeke gerilimine uyacak şekilde ayarlayarak senkronizasyon ve verimli güç aktarımı sağlar. Akım kontrol modunda VSI, kararlılığı korumak ve güç çıkarımını optimize etmek için PV dizisinin çıkış akımını düzenler.



Şekil 3.16. (a) gerilim kaynaklı inverter ve (b) akım kaynaklı inverterin blok diyagram gösterimi

Bu kontrol modları, PV sistem performansını optimize etmek için çıkış akımını ayarlayarak güneş aktivitesindeki dalgalanmalara uyum sağlayarak genel enerji kalitesini ve verimliliğini artırır. Yazarlar tarafından (Calais et al., 1999)'da kullanılan Şekil 3.16, H-köprülü inverter ve LCL filtreli tek fazlı VSI topolojisine genel bir bakışı göstermektedir ve bu düzenlemeye bir örnektir.

### 3.2.3.2. Akım Kaynaklı İnverter

Bir CSI, özel güç yönetimi özelliklerinin benzersiz avantajlar sunduğu şebekeye bağlı PV sistemleri de dahil olmak üzere bir dizi uygulamada yaygın olarak kullanılan bir güç elektroniği cihazıdır. Bir CSI'nin operasyonel tasarımının önemli bir bileşeni, sabit bir giriş akımı sağlamak için DC tarafında büyük bir indüktör kullanılmasıdır. İnverter adaptasyonunun hassas anahtarlama kontrol bileşeni, ayarlanabilir genişliklere sahip modüle edilmiş AC darbe sinyallerinin üretilmesini mümkün kılar (Kwak & Toliyat, 2006). Bir LCL filtresinin dahil edilmesi, bu darbeleri akım dalga biçimini yumuşatmaya yardımcı olur. Yük parametreleri çıkış geriliminin genliğini ve şeklini etkiler. VSI'larla karşılaştırıldığında, CSI'ların iletim kayıpları daha yüksektir ancak anahtarlama kayıpları da daha düşüktür. H-köprülü inverter ve LCL filtreli üç fazlı bir CSI topolojisi görsel olarak gösterilmekte ve bu dinamik tasarımın kapsamlı bir şekilde anlaşılmasını sağlamaktadır.

Şebekeye bağlı PV sistemler için VSI ve CSI arasında seçim yapma kararı, sistem gereksinimleri, kontrol şeması ve çalışma koşulları dahil olmak üzere çeşitli değişkenlere dayanmaktadır. Hem VSI hem de CSI'nin avantajları ve dezavantajları vardır. VSI tipik olarak şebekeye bağlı sistemler için seçilir çünkü doğal olarak daha iyi voltaj ve güç kalitesi kontrolü sağlar. Ancak CSI'nin de daha iyi akım düzenleme kabiliyeti ve daha basit topoloji gibi avantajları vardır (Attanasio et al., 2008). Kararın temeli, projenin özel gereksinimlerinin ve kısıtlamalarının ayrıntılı bir analizi olmalıdır.


### 3.2.4. İnverter Kontrolü

Şebekeye bağlı PV sistemlerde senkronizasyon, güvenilir çalışma ve optimum güç akışını sağlamak için inverter kontrolü çok önemlidir. Dönen referans çerçeve kontrolü, sabit referans çerçeve kontrolü ve doğal referans çerçeve kontrolü gibi inverter kontrol yöntemleri akımların ve gerilimlerin daha verimli kontrolünü sağlar. Evirici çıkışını şebeke gerilimi ile senkronize eden PLL entegrasyonu, bu yöntemler için gereken hassas senkronizasyonu sağlar (Ali et al., 2018; Sureshababu & Aseem, 2022). Buna ek olarak, gerilim seviyesini ayarlamak ve güç akışını kontrol etmek için PWM teknikleri de gereklidir (Kabalcı et al., 2021). Bu alt bölümde, daha gelişmiş inverter kontrol yöntemlerine geçmeden önce PLL ve PWM açıklanmaktadır.

#### 3.2.4.1. Sinüzoidal Darbe Genişlik Modülasyonu

Şebekeye bağlı PV sistemlerinde sinüzoidal PWM, darbe genişliklerini ayarlayarak, harmonikleri en aza indirerek ve gelişmiş kararlılık ve güç kalitesi için gerçek ve reaktif güç kontrolü sağlayarak senkronize ve verimli güç dönüşümü sağlayan önemli bir anahtarlama kontrol tekniğidir (YOUNAS et al., 2019).

Bu tür sistemlerde sabit bir DC bağlantı gerilimi elde etmek için, DC-DC dönüştürücü ilk olarak daha önceki bölümde açıklanan mümkün olan maksimum gücü elde etmek için MPPT kullanır. Bu güç daha sonra NPC gibi bir inverter kullanılarak şebekeye iletmek üzere AC gücüne dönüştürülür. Bu durumda, SPWM ikinci kademenin inverterinin kontrolünde önemli bir rol oynar. Sinüzoidal PWM'de inverter anahtarlama, **Şekil 3.17**'de gösterildiği gibi yüksek frekanslı bir üçgen taşıyıcı dalga ile düşük frekanslı bir sinüzoidal referans sinyalinin zıtlaştırılmasıyla modüle edilir (Kabalcı et al., 2021).



Şekil 3.17. Tek fazlı sinüzoidal PWM'nin anahtarlama sinyalleri

Denklem (3.26)'da modellenen modülasyon indeksi  $m_a$ , sinüzoidal referans sinyalinin genliklerinin taşıyıcı sinyale oranını ölçer ve daha sonra inverter çıkış voltajının temel bileşenini doğrusal olarak değiştirmek için kullanılır. Tek bir fazın kontrol mekanizması denklem (3.27) ile temsil edilir, burada  $V_{ph1}$  faz çıkış geriliminin tepe genliğidir.


$$m_a = V_m/V_c \quad (3.26)$$

$$V_{ph1} = 0.5 * m_a * V_s \quad (3.27)$$

Şebeke bağlantılı inverterlere bu modülasyon tekniği ile doğrusal ve ayarlanabilir gerilim kontrolü sağlayabilir. SPWM, transformatörüz, iki aşamalı, tek aşamalı, izole şebekeye bağlı ve çok aşamalı izole mikro inverter konfigürasyonları dahil olmak üzere çeşitli inverter topolojilerine kolayca dahil edilebilir (Daolian Chen et al., 2017).

### 3.2.4.2. Faz Kilitleme Döngüsü

Şebekeye bağlı PV dizisinde PLL, PV inverterlerin çıkış geriliminin fazını ve frekansını şebeke gerilimiyle senkronize etmek için kullanılır ve etkili güç enjeksiyonu sağlar, harmonikleri azaltır ve güç kalitesini artırır (Sureshababu & Aseem, 2022). Geleneksel faz algılama yöntemi şebeke geriliminin sıfır geçiş noktalarına dayanmasına rağmen, algılama boşlukları şebeke frekansının her yarım döngüsünde meydana geldiğinden ve ideal dinamik performanstan daha azına neden olduğundan dezavantajları vardır. Alternatif bir strateji, çeşitli PLL algoritmalarına entegre edilmiş senkron veya döner referans çerçevesi tekniğini kullanır. Bu yöntemde PLL bloğundan elde edilen dönüş açısı, hat-nötr gerilim verilerini dq formuna dönüştürmek için kullanılır. PLL kapalı döngüsü stabilize olur ve dq dönüşümünden gelen eksenin karesel bileşeni sıfır olur. **Şekil 3.18**'de (Gorai et al., 2020) sunulan PLL blok diyagramı senkronize referans çerçevesini göstermektedir.



**Şekil 3.18.** PLL senkronizasyon devresinin yapısı

PLL yapısı tipik olarak bir abc'den dq'ya dönüşüm ve ardından referans ve gerçek şebeke gerilimi arasındaki hatayı işlemek için bir PI kontrolörü içerir. PI denetleyici tarafından üretilen hata sinyali daha sonra evirici çıkışı ile şebeke gerilimi arasındaki sapmaları telafi eden bir integral teriminden geçirilerek uzun vadeli kararlılık sağlar ve yukarıdaki şekilde şematik olarak gösterildiği gibi senkronizasyon sürecini iyileştirir (Ali et al., 2018).



### 3.2.4.3. Döner Referans Çerçevesi (DQ) Kontrolü

Şebekeye bağlı PV sistemlerinde, dq döner referans çerçevesindeki akım ve gerilimi hassas bir şekilde kontrol etmek ve böylece sistem kararlılığını ve performansını artırmak için döner referans çerçeve kontrol yöntemi kullanılır. Park dönüşümü denklemleri, vektör kontrolü olarak da bilinen döner referans çerçevesi kontrolünde, üç fazlı abc akımlarını (3.28) ve (3.29) denklemlerinde modellendiği gibi bir dq döner referans çerçevesine dönüştürmek için kullanılır (O'Rourke et al., 2019).  $\theta$  açısı, a fazı ile d eksenini arasındaki dönüş açısını gösterir. d eksenini hat gerilim vektörüne paraleldir ve q eksenini 90 derecelik bir açığa sahiptir. Zamana bağlı sinüzoidal akımlar, PLL kullanılarak şebeke frekansına senkronize edilen bu döner referans çerçevesi kullanılarak sabit DC değerlerine dönüştürülür.

$$i_d = i_a \cos(\theta) + i_b \cos(\theta - 120^\circ) + i_c \cos(\theta + 120^\circ) \quad (3.28)$$

$$i_q = i_a \sin(\theta) + i_b \sin(\theta - 120^\circ) + i_c \sin(\theta + 120^\circ) \quad (3.29)$$

Bu şekilde,  $i_d$  ve  $i_q$  basit PI kontrolörleri kullanılarak ayrı ayrı düzenlenebilir. Salınım sinyallerinin olmaması nedeniyle, şebeke frekansında dönme kontrol işlemlerini basitleştirir. Döner çerçeve ile şebeke geriliminin gerçek fazı arasındaki farkı azaltmak için, ince ayarlı bir PLL aracılığıyla şebeke ile senkronizasyon gereklidir. Bu,  $i_d$  ve  $i_q$ 'nin ayrı bir şekilde kontrol edilmesine olanak tanıyarak şebekeye enjekte edilen aktif gücü dolaylı olarak kontrol eder ve gerekli reaktif güç veya güç faktörü ayarlamalarını yapar (Vasquez et al., 2020).

### 3.2.4.4. Sabit Referans Koordinat Eksenleri ( $\alpha\beta$ ) Kontrolü

Sabit referans kontrol sistemi, üç fazlı abc gerilimlerini ve akımlarını  $\alpha\beta$  sabit referans sistemine dönüştürerek şebekeye bağlı inverterleri dönel dönüşümlere gerek kalmadan kontrol eder (Abo-Elyousr & Abdelaziz, 2018). Bu, döner referans çerçeveleriyle ilişkili karmaşıklıkları ve şebeke ile doğru senkronizasyon ihtiyacını ortadan kaldırır. Sabit Referans Koordinat Eksenleri Kontrolü, Clarke dönüşümünün (3.30) ve (3.31) denklemlerini kullanarak üç fazlı abc akımlarını şebeke gerilim vektörü boyunca yönlendirilmiş sabit bir  $\alpha\beta$  referans çerçevesine dönüştürür.

$$\alpha = 2/3 * (i_a - i_b/2 - i_c/2) \quad (3.30)$$

$$\beta = (1/\sqrt{3} * (i_b - i_c)) \quad (3.31)$$

$\alpha\beta$  sabit referans çerçevesi şebekenin gerilim açısına göre sabittir ve dönen bir referans çerçevesi gibi dönmez (Rodríguez et al., 2012). Şebeke ile senkronize edilen  $\alpha$  akımı, şebeke ile senkronize edilmiş pozitif dizi bileşenidir ve  $\beta$  negatif diziyi temsil eder. Dengeli üç fazlı çalışma, sabit referans çerçevesinin  $\alpha$  ve  $\beta$ 'sını kontrol ederek de elde edilebilir. Sabit bir sistemde kararlı durum hataları olmadan doğru akım kontrolü elde etmek için, şebeke frekansında büyük bir kazanç sağlayan bir PR kontrolörü kullanılır (Vanti et al., 2022). Şebeke senkronizasyonu ve akım regülasyonu PR kontrol kullanılarak kontrol edilirken, sabit referans kontrolü  $\alpha$  ve  $\beta$  bileşenleriyle ilgilenir.

#### 3.2.4.5. Doğal Çerçeve Kontrolü


Doğal çerçeve kontrolü, çerçeve dönüşümlerinden kaçınarak üç fazlı abc akımlarını doğrudan zaman alanında kontrol eden basit bir tekniktir. Kontrol stratejisi basitleştirilmiş olsa da faz-faz ayrıştırması yoktur. Doğal çerçeve kontrolü, çerçeve dönüşümlerine ihtiyaç duymadan abc akımlarını doğrudan kontrol eder (Madouh et al., 2012). Geçici durum performansı, her bir fazın bağımsız olarak ele alınmasıyla iyileştirilebilir. Ancak, ayrıştırma eksikliği sinüzoidal sinyalleri izlemek için gereken kontrol sisteminin karmaşıklığını artırır. Her fazın kendi PI kontrolörü vardır ve fazlar arasındaki sistem etkileşimlerini hesaba katmak zordur. Doğal çerçeve kontrolü, Park veya Clarke dönüşümlerini kullanarak sabit çerçeveleri döndürmez veya takip etmez. Bu, çerçeve değişikliklerinin hesaplama yükünü ortadan kaldırır, ancak ayırık kontrolün avantajlarından vazgeçer (Ting et al., 2016), ancak ayrıştırma tekniklerinin olmaması performansını ve verimliliğini artırır.

#### 3.2.5. Şebekeye Bağlı PV İnverterin Kademeli Kontrolü

Bu alt bölümde, şebekeye bağlı inverterlerin optimum güç akışını sağlayan önemli kademeli kontrol döngüleri analiz edilmektedir. Bu kontrol döngüleri sabit güç enjeksiyonu, şebeke bozukluklarına hızlı tepki ve verimli güç kalitesinin korunması için çok önemlidir. Gerilim kontrol döngüsü ve akım kontrol döngüsü, hassas şebeke senkronizasyonu ve güvenilir güç dağıtımı elde etmek için bu mimarinin temel bileşenleridir. Her bir kontrol döngüsünün ayrıntılı açıklaması aşağıdaki alt bölümlerde sunulmuştur.

### 3.2.5.1. Gerilim Kontrol Döngüsü (Dış Döngü)

Şebeke bağlantılı evirici sistemlerinde, gerilim kontrolü hiyerarşik bir yapıda dış kontrol döngüsü olarak görev yapar ve senkron çalışma sırasında şebeke gerilimine uyması için evirici çıkış gerilimini dq senkron çerçevesinde düzenler (Altin et al., 2018). Gerilim döngüsü, ölçülen gerilimler ile PLL tarafından üretilen  $v_d^*$  ve  $v_q^*$  referans gerilimleri arasındaki hataları en aza indirmek için iki PI denetleyicisi kullanır ve gözlemlenen üç fazlı şebeke gerilimini abc'den dq'ya çevirir. Daha yavaş olan dış gerilim düzenleme döngüsü, şebeke ile faz senkronizasyonunu korurken evirici çıkış gerilimini sürekli olarak şebeke referans gerilimine ayarlayarak daha hızlı olan iç kontrol döngüsü için referans akımı ayarlar. Gerilim kontrol döngüsünün çalışmasını gösteren şematik diyagram Şekil 3.19'da gösterilmiştir.



Şekil 3.19. Gerilim ve akım kontrol döngüsünün çalışmasını gösteren şematik diyagram

Ayrıca voltaj regülatörü, PV kaynağından şebekeye güç aktarımını en üst düzeye çıkarmak için gereken DC bağlantı voltajını kontrol eder (Huang et al., 2013). PI regülatörlerinin kazançları, kararlılık ve performans sağlamak için dikkatlice ayarlanmalıdır. Şebekeye bağlı eviricinin voltaj regülasyonu, senkronizasyon ve güç dağıtımını aynı anda gerçekleştirme yeteneği harici bir voltaj regülasyon döngüsü ile sağlanır.

### 3.2.5.2. Akım Kontrol Döngüsü (İç Döngü)

Şebeke bağlantılı inverterlerde, akım kontrol döngüsü daha hızlı bir iç döngü olarak hareket eder ve harici gerilim döngüsü tarafından ayarlanan referans değerleri takip etmek için dq çerçevesindeki çıkış AC akımını kontrol eder (Lopez-Santos, 2015). PWM ve inverter anahtarlarını kontrol etmek için bağımsız PI kontrolörleri, akım hatalarını en aza indirmek için  $v_d^*$  ve  $v_q^*$  gerilim referans değerlerini üretir (Shayestegan, 2018). Dış gerilim döngüsünden daha yüksek bir frekansta çalışan bir iç akım döngüsü, kararlı çalışma ve sorunsuz şebeke entegrasyonu için akım ayar noktalarının hassas kontrolünü sağlar (Altin et al., 2018). **Şekil 3.19'**da, iç akım kontrol döngüsünün şematik gösterimini temsil etmektedir.

d-ekseni akım ayar noktası d-akım bağlantı gerilimiyle eşleştirilir ve reaktif güç q-ekseni bileşeni tarafından kontrol edilir (Lopez-Santos, 2015). İç akım kontrol döngüsü, PV dizisinin çıkış akımını referanslarla karşılaştırarak optimum güç kalitesi ve kararlılık için şebekeye hassas, harmoniksiz akım enjeksiyonunu kontrol eder.

Şebekeye bağlı PV sistemlerinde hem harici hem de dahili kontrol döngülerinin birleşik rolü vazgeçilmezdir. Park-Clarke dönüşümü ve PLL gibi kontrol veya dönüşüm teknikleri bu entegrasyona önemli bir katkı sağlar. Harici kontrol veya voltaj kontrol döngüsü DC bağlantı voltajının düzenlenmesine yardımcı olur ve böylece voltaj dalgalanmalarını azaltır ve sabit bir güç akışı sağlar. Eş zamanlı olarak, dahili kontrol veya akım kontrol döngüsü şebekeye doğru akım aktarımını sağlar ve PV dizisinin çıkış gücünü referans değerlerle hizalamaya yardımcı olur. Bu hassas etkileşim, şebeke uyumluluğunu ve güç kalitesini büyük ölçüde iyileştirir. Buna ek olarak, LCL filtresi, harmonik içerikleri azaltmak ve şebekeye bağlı PV sistemin performansını ve verimliliğini artırmak için evirici ile şebeke arasındaki en önemli unsurlardan biridir. Bu alt bölüm, söz konusu sistem için LCL filtresinin tasarımı ile devam etmektedir.

### 3.2.6. Şebekeye Bağlı PV Sistem için LCL Filtre Tasarımı

İnverter ve şebeke arasındaki çıkış LCL filtresi, güç kalitesi standartlarını karşılamak için anahtarlama harmoniklerinin zayıflatılmasında hayati bir rol oynar (Chatterjee, 2023). Filtre tasarım süreci, zayıflatma hedeflerine, kararlılığa ve maliyet etkinliğine ulaşmak için indüktör ve kapasitör değerlerinin seçimini içerir. İndüktör (L) ve kapasitör (C) değerlerinin gerekli zayıflama, kararlılık ve maliyet etkinliği göz önünde

bulundurularak seçilmesi gerekir (Pilla et al., 2018). Filtre kesim frekansı ( $f_c$ ), harmonik içeriği bastırmak için kasıtlı olarak inverter anahtarlama frekansının ( $f_s$ ) altına ayarlanır. Rezonans frekansı ( $f_{res}$ ), kararlılığı korumak için  $f_c$ 'den daha yüksek olmalıdır. Benzer şekilde, empedans parametrelerinin  $L1/L2$  oranının 0,1'in altında tutulması gerekir. Bu parametre, güvenilir filtre performansı ve etkili rezonans bastırma desteği için en yüksek öneme sahiptir.  $L1/L2$  oranı 0,1'i aşarsa, istenmeyen rezonanslar ve empedans farklılıkları oluşabilir ve bu da LCL filtresinin filtreleme kabiliyetine ve genel performansına zarar verebilir. Rezonans elde etmek için bu bileşenlerin dengelenmesi gerekir ve sönümlleme direnci ( $R$ ) gerekli sönümlleme ve geçici tepkinin sağlanmasına yardımcı olur.

LCL filtresinin tasarım sürecinde kullanılan matematiksel denklemler aşağıda modellenmiştir. Bu LC parametre değerlerinin seçimi, PV dizisinin nominal gücü ve DC bağlantı voltajı dahil olmak üzere sistem yapılandırmasına bağlıdır. LCL bileşenleri, istenmeyen harmoniklerin giderilmesine yardımcı olan bir rezonans noktası oluşturmak için seçilir. Belirli harmonikleri hedefleyen rezonans frekansının formülü denklem (3.32)'de modellenmiştir.  $L1$  ve  $L2$  değerleri denklem (3.33) kullanılarak hesaplanır. Rezonansı gerçekleştirmek için,  $C$  değeri indüktör değerinin tamamlayıcısı olarak kabul edilir. Sönümlleme oranı denklem (3.34) kullanılarak hesaplanır. Sönümlleme direncini hesaplamak için denklem (3.35) kullanılır. Dolayısıyla, rezonans frekansındaki LCL filtre empedansı denklem (3.36) ile modellenir.

$$f_{res} = 1/(2 * \pi * \sqrt{L * C}) \quad (3.32)$$

$$L = 1/(4 * \pi^2 * C * f_{res}^2) \quad (3.33)$$

$$\xi = R/(2 * \sqrt{L/C}) \quad (3.34)$$

$$R = 2 * \xi * \sqrt{L/C} \quad (3.35)$$

$$Z = R + j\omega L + 1/(j\omega C) \quad (3.36)$$

LCL filtresinin başarılı rezonans tasarımı, şebekeye bağlı PV sistemlerinde yüksek frekanslı harmoniklerin azaltılması için özellikle uygundur (Mishra et al., 2023). Filtre, yüksek geçişli bir filtre görevi görerek evirici tarafından üretilen yüksek frekanslı harmonikleri zayıflatır ve şebekenin temel frekansı gibi daha düşük frekanslı bileşenlerin geçmesine izin verir. Bu işlev, istenmeyen yüksek frekanslı harmoniklerin şebekeyi etkilemeden önce filtrelenmesini ve böylece güç kalitesinin korunmasını sağlar.

### 3.3. Bölüm Özeti

Bu bölümde, iki aşamalı şebeke bağlantılı bir PV sistem ayrıntılı olarak ele alınmaktadır. İlk olarak, yükseltici tip DC-DC dönüştürücü tasarımı ve PV panel teknolojisi analiz edilmiştir. P&O, ANN (DNN) ve RNN gibi MPPT kontrolörleri de tartışılmış ve önerilen LSTM modeli hakkında kısa bilgi verilmiştir. Bir sonraki bölümde (Bölüm 4), stack LSTM'lere dayalı bir MPPT kontrolörü önerilmektedir. Bunu şebekeye bağlı eviricinin topolojisi, tasarımı ve kontrol stratejisinin açıklaması takip etmektedir. Bölüm 4'te, NPC eviricilerin uygulanması ayrıntılı olarak açıklanmaktadır. Bu bölüm, şebekeye bağlı PV sistemlerin entegrasyon ve kontrol stratejisinin anlaşılmasını kolaylaştırmaktadır.



#### 4. ÖNERİLEN ARAŞTIRMA

Bu bölümde, önerilen araştırmanın altında yatan temel kavramlar açıklanmaktadır. Bu tez, Derin Öğrenme (DL) tabanlı bir Maksimum Güç Noktası İzleme (MPPT) kontrolörünü şebekeye bağlı bir solar Fotovoltaik (PV) sistemine entegre etmek için yeni bir konsept önermektedir. Makine Öğrenimi (ML) ve DL, şu anda çeşitli Endüstri 4.0 uygulamalarına ve Endüstri 5.0 uygulamalarına hizmet eden Yapay Zekanın (AI) gelişmekte olan alt alanlarıdır (Akundi et al., 2022). Bu nedenle, solar PV sisteminde MPPT kontrolörü olarak Uzun Kısa Süreli Bellek (LSTM) ağı DL algoritmasının entegrasyonu gibi gelişmiş teknolojilerin kullanılması, genel performansı ve verimliliği daha da artırmaktadır. Bu nedenle, bu bölüm önerilen araştırma yaklaşımına kapsamlı bir genel bakış sağlamakta ve PV sistemde MPPT için LSTM ağlarının kullanımına odaklanmaktadır. Başarılı bir MPPT kontrolörü tasarlamak için LSTM ağ mimarisine, aktivasyon fonksiyonlarına, hiper parametrelerine ve çeşitli LSTM ağ türlerine bakmak faydalı olabilir. Buna ek olarak, performans ölçütlerinin ve eğitim seçeneklerinin değerlendirilmesi, araştırmacılara LSTM ağlarını kullanarak güneş enerjisinden elektrik güç üretimi sistemlerini optimize etmek için önemli araçlar sağlar, böylece yenilenebilir enerji kullanımını artırır ve sürdürülebilir enerji üretimini destekler. Bu bölümde ele alınan LSTM ağının ana konuları aşağıda vurgulanmıştır:

- Giriş, arka plan ve LSTM Ağlarına genel bakış
- LSTM Ağlarının yapısı ve mimarisi
- ML ve DL Modellerinde Kullanılan Aktivasyon Fonksiyonları
- DL Modellerinde Hiperparametrelerin Seçimi
- LSTM Ağlarının Türleri
- Önerilen stack LSTM ağı
- MPPT Kontrolörü olarak önerilen LSTM modeli
- Önerilen Kontrolörün Giriş ve Çıkışları için Model Tasarımı
- DL modellerinin eğitimi ve test edilmesi
- DL modelleri için performans değerlendirme metrikleri

Bu bölüm, önerilen çalışmanın yukarıda belirtilen bileşenlerinin her birinin adım adım açıklamasıyla devam etmektedir.

#### 4.1. LSTM Ağlarının Giriş

Bu bölüm, LSTM ağlarına genel bakışı ve ardından çeşitli sektörlerdeki uygulamalarını özetlemektedir. Sıralı veri kümelerindeki uzak ilişkileri tespit etmek için LSTM ağlarının önemini vurgulamaktadır. Bölüm, LSTM ağının genel görünümü, tarihsel dönüşümü ve evrimi ile farklı sektörlerdeki uygulamaları ile devam etmektedir.

##### 4.1.1. LSTM Ağlarına Genel Bakış

Son yıllarda, Yapay Sinir Ağlarının (ANN) zaman serisi tahmini ve öngörü uygulamalarında kullanılması, tarihsel girdi ile öngörülen çıktı arasındaki karmaşık ilişkilerin modellenmesinde iyi bir doğruluk sunmuştur (Fine, 2005). ANN'larda bilgi sadece tek bir yönde, girdi katmanından çıktı katmanına doğru akar. Buna ek olarak, ANN girdi ve çıktı arasındaki geçmiş veri bağımlılıklarını verimli bir şekilde ele alamamaktadır. Bu nedenle, ANN modelleri normalde sınıflandırma ve regresyon modellerinde kullanılır.

Öte yandan, Tekrarlayan Sinir Ağı (RNN) bilgiyi kalıcı hale getiren döngülere sahiptir, bu da onu zaman serisi verileri, metin verileri ve konuşma verileri gibi sıralı verilerin işlenmesi için uygun hale getirir. Geleneksel ANN'larla ilişkili zorlukların üstesinden gelmek için RNN, çıktısı önceki hesaplamalara bağlı olan bir dizi veriyi işlemek için uzmanlaşmış bir ANN türüdür. RNN'ler zaman serileri, konuşma ve dil verileri gibi sıralı girdiye sahip görevler için kullanılır. RNN'ler aynı anda birkaç girdi alabilir ve zaman serisi verilerini tahmin etmek için yararlı bir dizi çıktı üretebilir. RNN, önceki zaman adımlarından gelen bilgileri dahil etmek için ağ döngülerini kullanır ve geleneksel ANN'lardan daha yüksek tahmin doğruluğu sunar (Tsantekidis et al., 2022). RNN'ler kısa vadeli bağıntıları yönetmek için daha iyi doğruluk ve performans sunarken, "kaybolan gradyan" ve "artan gradyan" sorunları nedeniyle uzun vadeli bağımlılıklarla mücadele ederler. Gradyan kaybolması, gradyanlar üstel olarak azaldığında meydana gelir ve daha önceki zaman adımlarından bilgilerin hatırlanmasını zorlaştırır. Gradyan büyümesi, gradyan eğitim sırasında üstel olarak arttığında ve kararsızlığa neden olduğunda ortaya çıkar. LSTM ve Gated Recurrent Units (GRU) bu gradyan sorunlarıyla başa çıkmak için iyi alternatiflerdir. Bu mimariler uzun vadeli bağımlılıkları yakalamada daha iyi performans gösterir.



LSTM ağı, gradyanları ve bilgi akışını kontrol etmek için özel geçit mekanizmaları içerir (Duan et al., 2022; Indrakumari et al., 2021). LSTM ağlarında, RNN'lerin kaybolan ve patlayan gradyanlar gibi sorunlarının üstesinden gelen temel unsur, bir bellek hücresinin dahil edilmesidir. Bu hafıza hücresi, LSTM ağlarının uzun diziler boyunca bilgileri seçici olarak tutmasına ve unutmasına olanak tanıyarak verilerdeki uzun vadeli bağımlılıkları yakalamalarını sağlar. LSTM ağları, bellek hücreleri ve daha sofistike bir geçit mekanizması ekleyerek kaybolan gradyanlar sorununun üstesinden gelebilir ve sıralı verileri gelişmiş doğruluk ve performansla etkili bir şekilde işleyebilir. Bu bellek hücreleri sigmoid ve eleman-bilge çarpımından oluşan kapı mekanizmalarıyla kontrol edilir. Bu modifikasyonların uzun vadeli bağımlılık sorununu ele almada etkili olduğu kanıtlanmış ve çeşitli zaman serisi tahmin uygulamalarında gelişmiş performans göstermiştir (ilerleyen bölüme bakınız). Bu değişikliklerin uzun vadeli bağımlılık sorununu ele almada etkili olduğu kanıtlanmış ve çeşitli zaman serisi tahmin uygulamalarında gelişmiş performans göstermiştir.

#### 4.1.2. LSTM Ağının Uygulamaları

LSTM ağları, uzun vadeli bağımlılıkları yakalama ve sıralı verileri işleme yetenekleriyle çeşitli alanlardaki uygulamaları ortaya çıkarmıştır. LSTM'nin hâkim teknoloji sektörlerindeki uygulamalarından birkaçı aşağıda listelenmiştir:

##### 4.1.2.1. Zaman Serisi Analizi ve Tahmin Uygulamaları

- **Solar PV'de MPP Çıkarımı:** Önerilen araştırmanın kapsamına göre, LSTM ağları, solar PV sisteminin MPPT'sini izlemek için MPPT algoritmaları olarak kullanılabilme özelliğine sahiptir. LSTM ağlarının MPPT tahmini ve takibindeki bu uygulaması, PV sistemlerinin verimli çalışmasına katkıda bulunur. Sonraki noktalarda bahsedilen uygulamalarda, araştırmacılar LSTM ağını tahmin amacıyla zaten kullanmış ve daha yüksek doğruluk sağlamışlardır.
- **Hava Durumu Tahmini:** LSTM ağları, sıcaklık ve ısınım gibi geçmiş hava durumu verilerini analiz etmek ve doğru tahminler yapmak için kullanılmış ve gelişmiş hava tahmin modellerine katkıda bulunmuştur (Hossain & Mahmood, 2020).

- **Enerji Yüğü Tahmini:** LSTM ağları, enerji tüketim modellerini tahmin etmek için uygulanmış ve enerji şirketlerinin enerji üretimini ve dağıtımını optimize etmesine yardımcı olmuştur. (Bouktif et al., 2020)'deki yazarlar elektrik yükünü tahmin etmek için LSTM yaklaşımını kullanmışlardır.
- **Borsa Tahmini:** LSTM ağları, (Kalbandi et al., 2021)'deki yazarlar tarafından geçmiş fiyat verilerindeki kalıpları ve bağımlılıkları yakalayarak hisse senedi fiyatlarını tahmin etmek ve yatırımcıların bilinçli kararlar almasına yardımcı olmak için kullanılmıştır.

#### 4.1.2.2. Doğal Dil İşleme (NLP) Uygulamaları

LSTM ağları, bir cümlelin bağlamını modelleyerek doğru çevirileri anlamak ve üretmek için Google Translate gibi makine çeviri sistemlerinde kullanılmıştır. Benzer şekilde, LSTM ağları konuşma tanıma sistemlerinde, konuşulan kelimelerin gelişmiş doğrulukla yazılı metne çevrilmesine yardımcı olmak için kullanılmıştır (Al-muzaini et al., 2018). Modern jeneratif AI sohbet robotları da LSTM modelleri kavramlarını kullanmaktadır.

#### 4.1.2.3. Sağlık ve Biyomedikal Uygulamaları

LSTM ağları, hastalıkları teşhis ve tahmin etmek için hasta verilerini (örneğin elektronik tıbbi kayıtlar ve tıbbi görüntüler) analiz etmede sağlık uzmanlarını desteklemek için kullanılır (Al-muzaini et al., 2018). Buna ek olarak, LSTM ağları, örneğin yaşlılarda düşmeleri tespit eden sistemlerde ve fitness ekipmanlarında aktivite izleme için insan faaliyetlerini izlemek ve sınıflandırmak için de kullanılır.

#### 4.1.2.4. Otonom Araçlar ve Robotik

Endüstri 4.0'dan 5.0'a geçişle birlikte otomasyon ve robotik kullanımı hızla artmaktadır. Bu bağlamda LSTM'ler, sürücüsüz araçlar için şerit algılama, nesne tanıma ve diğer yol kullanıcılarının davranışlarını tahmin etme gibi otonom sürüş sistemlerinde önemli bir rol oynamaktadır (Yuntao Xue & Chen, 2023). LSTM ağları, robotların birbirini izleyen davranış kalıplarını öğrenerek ve tahmin ederek

karmaşık görevleri yerine getirmelerini sağlamak için robotikte de kullanılmaktadır.


LSTM ağları, çeşitli alanlarda belirli veri yönetimi ve zamana bağlı modelleme için mükemmel uyarlanabilirlik göstermiştir; LSTM'nin bu esnekliği, onu zamansal olarak bağlantılı veriler ve büyük veri kümeleri ile zor görevlerin üstesinden gelmek için etkili bir araç haline getirir.

## 4.2. LSTM Ağ Mimarisi

Bir LSTM hücre mimarisinin yapısı, **Şekil 4.1**'de gösterildiği gibi giriş kapısı, unutma kapısı, bellek hücresi (bellek ögesi veya hücre durumu) ve çıkış kapısından oluşur (Patterson & Gibson, 2019). Bu bölümde ayrıca her bir kapının ve hücre durumunun ayrıntılı açıklaması, matematiksel denklemleri ve işleyişi anlatılmaktadır.

### 4.2.1. Bir LSTM Hücresinin Kapıları (Gates)

Tek bir LSTM hücresinin toplam üç kapısı (giriş kapısı, unutma kapısı ve çıkış kapısı) ve bir hücre durumu vardır. Giriş kapısı, bellek hücresinde depolanan yeni veri bilgisinin miktarını kontrol eder. Nokta çarpımı bir sigmoid katman ile birlikte kullanılır. Mevcut girdi ve önceki gizli durum göz önüne alındığında, sigmoid katman her girdi bileşeni için 0 ile 1 arasında bir değer döndürür ve bellek hücresine ne kadar bilgi girilmesi gerektiğini gösterir.



**Şekil 4.1.** LSTM hücresi ile örneklendirilen temel LSTM bileşeninin ağ yapısı

Bu sigmoid çıktı ve tanh çıktısı noktasal olarak çarpılır ve girdi veri aralığını -1 ve 1'e dönüştürür. Sonuç olarak, girdinin filtrelenmiş bir versiyonu bellek hücresi durumuna eklenir ve LSTM ağına hangi yeni bilgilerin depolanacağını yönetme yeteneği verir. Bellek hücreleri ve geçitlime tekniklerinin kullanımı sayesinde LSTM ağları zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalayabilir (Gers et al., n.d.). Bu şekilde LSTM ağları, bilgileri seçici olarak depolayarak, unutarak ve güncelleyerek zaman serisi verilerindeki uzun vadeli bağımlılıkları verimli bir şekilde ele alabilir.

Aşağıdaki bölümlerde LSTM hücresinin yapısı, matematiksel formülü ve her bir kapısının çalışması açıklanmaktadır.

#### 4.2.1.1. Unutma Kapısı (Forget Gate)

Bir LSTM hücresindeki unutma kapısı, hücre durumundan bilginin tutulmasını veya çıkarılmasını kontrol etmekten sorumludur. Mevcut zaman adımının ve önceki gizli durumun giriş verilerini alır. Bu girdiler daha sonra sigmoid bir aktivasyon fonksiyonu tarafından işlenir ve hücre durumunun her bir elemanı için 0 ile 1 arasında değerlere sahip bir çıkış vektörü elde edilir (KARABİNAOĞLU et al., 2022). Unutma kapısının amacı, bir önceki hücre durumundan hangi bilginin atılması gerektiğine karar vermektir. Değerin 0'a yakın olması söz konusu hücre durumu unsurunun unutulması veya atılması gerektiğini gösterirken, 1'e yakın bir değer bilginin korunması ve saklanması gerektiğini gösterir. Unutma kapısının amacı, bir önceki hücre durumundan hangi bilgilerin atılması gerektiğine karar vermektir. 0'a yakın bir değer, hücre durumunun ilgili unsurunun unutulması veya atılması gerektiğini gösterirken, 1'e yakın bir değer bilginin tutulması ve saklanması gerektiğini gösterir. Unutma kapısı için matematiksel denklem (4.1)'de gösterilmiştir.

$$f_t = \sigma (W_f \cdot [h_{t-1}, X_t] + b_f) \quad (4.1)$$

Bu denklemde  $f_t$ , t zaman adımındaki unutma geçidinin çıkışını temsil eder. Önceki gizli durumun ve mevcut girdinin doğrusal kombinasyonu, sigmoid aktivasyon fonksiyonundan ( $\sigma$ ) geçirilen  $[h_{t-1}, X_t]$  ile temsil edilir. Doğrusal kombinasyonla ilişkili ağırlıklar ve yanlılık sırasıyla  $W_f$  ve  $b_f$  ile gösterilir. Unutma kapısı, önceki hücre durumundan ne kadar bilginin LSTM hücresi tarafından tutulacağını veya unutulacağını kontrol eder. Önceki hücre durumunun bileşenlerini seçici olarak ölçeklendirerek ve 0 ile

1 arasında değerler üreterek LSTM hücresindeki uyarlanabilir unutma sürecini hızlandırır.

#### 4.2.1.2. Giriş Kapısı (Input Gate)

Giriş kapısı, yeni bilgilerin hücre durumuna nasıl girdiğini kontrol eden bir LSTM ağının temel unsurlarından biridir. Mevcut girdiyi önceki gizli durumla birleştirmek için bir sigmoid aktivasyon fonksiyonu kullanır ve girdi bilgisinin önemini veya alaka düzeyini gösteren 0 ile 1 arasında bir çıktı değeri üretir. Aday değer hiperbolik tanjant aktivasyonu ile elde edildikten sonra, kapı bu değer birim duruma dahil edilip edilmeyeceğine karar verir (Indrakumari et al., 2021). Giriş kapısının çıktısını aday değer ögesiyle çarparak, LSTM önemli girdileri tutabilir ve daha az önemli bilgileri göz ardı edebilir. Bu şekilde, giriş kapısı yeni bilgilerin hücre durumu üzerindeki etkilerini seçici olarak kontrol edebilir. Giriş kapısının matematiksel formu (4.2)'de gösterilmiştir.

$$i_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4.2)$$

Denklem (4.2)'de  $i_t$ , t zamanındaki giriş kapısının çıkışıdır.  $\sigma$  sigmoid fonksiyonu,  $[h_{t-1}, x_t]$  olarak gösterilen önceki gizli durum  $h_{t-1}$  ve mevcut giriş  $x_t$ 'nin doğrusal kombinasyonuna uygulanır.  $W_i$  Ağırlıklar ve  $b_i$  bu doğrusal kombinasyon girdisi ve önceki gizli durumla ilişkili yanlılık terimleridir. Hücre durumunu değiştirmek için yeni giriş verilerinin önemi, bir LSTM hücresindeki giriş kapısı tarafından belirlenir. Bir sigmoid aktivasyon fonksiyonu kullanarak ne kadar yeni bilginin asimile edilmesi gerektiğini gösteren 0 ile 1 arasında değerler üretir. LSTM hücresi, anahtar girdiyi seçici olarak tutması nedeniyle sıralı verilerdeki uzun vadeli bağımlılıkları verimli bir şekilde tanımlayabilir ve modelleyebilir.


#### 4.2.1.3. Çıkış Kapısı (Output Gate)

LSTM hücresinin çıkış kapısı, hücre durumundan çıkışa veya tahmine bilgi akışını yönetmekten sorumludur. Çıkış kapısı mevcut girdiyi ve önceki gizli durumu girdi olarak alır. Her iki girdi de daha sonra sigmoid aktivasyon fonksiyonu aracılığıyla işlenir ve 0 ile 1 arasında değişen değerlere sahip bir çıktı vektörü verir. Çıkış kapısı, hücre durumunda tutulan verilerin çıktıyı oluşturmak için önemli veya ilgili olup olmadığını seçer. 1'e yakın bir değer, çıktı üzerinde büyük bir alaka ve önemli bir etki anlamına

gelirken, 0'a yakın bir değer, hücre durumunun karşılık gelen öğesinin çıktı üzerinde çok az etkisi olması gerektiğini önerir (Jason, 2018). Çıktı kapısının matematiksel formu (4.3)'te sunulmuştur.

$$O_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (4.3)$$

Burada,  $W_o$  önceki gizli durum  $h_{t-1}$  ve mevcut giriş  $x_t$ 'nin birleştirilmesi için ağırlık matrisidir.  $[h_{t-1}, X_t]$  bölümü önceki gizli durum ile mevcut girdinin birleşimini temsil eder,  $b_o$  çıkış kapısı için bias terimidir ve  $\sigma$  giriş değerlerini 0 ile 1 arasında düzenleyen sigmoid aktivasyon fonksiyonudur. Tüm kapıların bireysel bilgileri Şekil 4.2'de gösterilmiştir.



Şekil 4.2. Bir LSTM hücresindeki üç kapının her birinin ayrı ayrı vurgulanması

Tüm kapı bilgilerinin hücre durumuyla güçlü bir bağlantısı vardır, bu nedenle bu alt bölüm hücre durumunun ayrıntılı bir açıklamasıyla devam etmektedir.

#### 4.2.2. LSTM Hücresinde Hücre Durumu (Bellek Hücresi)

Bir LSTM hücresinin gizli durumu, belirli bir zaman adımına kadar giriş dizisinden ilgili verileri toplar ve kodlar. Zaman serisi tahmini de dahil olmak üzere çeşitli uygulamalar için gereklidir ve çıkış kapısı kullanılarak hücre durumundan üretilir. Gizli durum hem son hem de geçmiş verileri birleştirerek giriş dizisinin sıkıştırılmış bir temsili olarak hizmet eder. Gizli durum, uzun vadeli bağımlılıkların ve karmaşık örüntülerin öğrenilmesini kolaylaştırır. Zaman içindeki örüntüleri tanımayı ve bunlar hakkında tahminlerde bulunmayı içeren faaliyetler için gereklidir. Hücre durumunun matematiksel gösterimi denklem (4.4)'te verilmiştir.

$$h_t = O_t \tanh(C_t) \quad (4.4)$$


Son olarak, hücre durumu  $C_t$  ve gizli durum  $h_t$  LSTM'nin çıktısıdır ve bir sonraki katmana geçer. Hata hedef kümeye yaklaşıncaya kadar süreç tekrarlanır. Modelin ağırlık parametresini ve sapma terimlerini öğrenerek ve optimize ederek, LSTM ağına çıkışı ile gerçek eğitim örnekleri arasındaki sapma minimuma indirilir.

(1)'den (4)'e kadar olan denklemler, yazarların (Duan et al., 2022)'deki açıklamalarına göre vurgulanmıştır. Bir LSTM hücresinde, giriş kapısı, unutma kapısı ve çıkış kapısının her biri mevcut girişi ve önceki gizli durumu giriş olarak kabul eder ve daha sonra bu girişleri 0 ile 1 arasında değerler veren sigmoid aktivasyonundan geçirir, ancak her kapının LSTM mimarisinde farklı bir işlevi vardır. Unutma kapısı önceki hücre durumundan bilginin silinmesini veya korunmasını yönetirken, giriş kapısı hücre durumunun güncellenmesi için yeni giriş bilgisinin önemini belirler. Unutma kapısı mevcut bilgiyi seçici olarak korur veya atarken, giriş kapısı yalnızca uygun olduğunda yeni bilgi eklemeye odaklanır. Çıkış kapısı, hücre durumundan çıkışa bilgi akışını kontrol eder ve hücre durumundan gelen bilginin istenen çıktıyı üretmek için gerekli olup olmadığını belirler. Bir LSTM'deki kapıların (unutma kapısı, giriş kapısı ve çıkış kapısı) ve hücre durumlarının kombinasyonu, sıralı verilerdeki uzun vadeli bağımlılıkları etkili bir şekilde yakalamasına ve modellenmesine olanak tanır. Buna ek olarak, aktivasyon fonksiyonları LSTM ağlarında doğrusal olmayan özellikleri ortaya çıkaran, ağına karmaşık zamansal ilişkileri modellemesini ve sıralı verilerdeki uzun vadeli bağımlılıkları yakalamasını sağlayan çok önemli bir unsurdur.

#### 4.3. LSTM Ağları İçin Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, ANN'larda ve ML modellerinde bir nöronun çıktısına doğrusal olmayan özellikler katmak için kullanılan matematiksel fonksiyonlardır. LSTM'de aktivasyon fonksiyonları tek tek nöronlar yerine LSTM hücresi içinde kullanılır. Aktivasyon fonksiyonu, ağırlıklı toplamı hesaplayarak ve buna bias ekleyerek bir nöronun veya LSTM hücresinin etkinleştirilip etkinleştirilmeyeceğine karar verir. Aktivasyon fonksiyonunun amacı, sinir ağına öğrenmesi ve daha karmaşık görevleri yerine getirmesi için gerekli olan bir nöronun çıktısına doğrusal olmayan bir özellik katmaktır (Sharma et al., 2020), (Husein & Chung, 2019). İki tür aktivasyon fonksiyonu vardır: doğrusal ve doğrusal olmayan aktivasyon fonksiyonları. Doğrusal aktivasyon fonksiyonları, ANN'lara beslenen olağan verilerin karmaşıklığına veya çeşitli

parametrelerine yardımcı olmayan basit fonksiyonlardır. Öte yandan, doğrusal olmayan aktivasyon fonksiyonları, düğümlerin verilerdeki daha karmaşık yapıları öğrenmesine izin verdiği için tercih edilir. Birkaç önemli aktivasyon fonksiyonunun grafiksel gösterimi Şekil 4.3'te verilmektedir.

| ML ve DL Algoritmalarında Genel Olarak Kullanılan Aktivasyon Fonksiyonları |                                                                                    |                                                                                                                      |                                                                                                                 |                     |
|----------------------------------------------------------------------------|------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------|---------------------|
| Name ↕                                                                     | Plot                                                                               | Function, $f(x)$ ↕                                                                                                   | Derivative of $f$ , $f'(x)$ ↕                                                                                   | Range ↕             |
| Identity                                                                   |   | $x$                                                                                                                  | 1                                                                                                               | $(-\infty, \infty)$ |
| Binary step                                                                |   | $\begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$                                          | $\begin{cases} 0 & \text{if } x \neq 0 \\ \text{undefined} & \text{if } x = 0 \end{cases}$                      | $\{0, 1\}$          |
| Logistic, sigmoid, or soft step                                            |   | $\sigma(x) = \frac{1}{1 + e^{-x}}$ [1]                                                                               | $f(x)(1 - f(x))$                                                                                                | $(0, 1)$            |
| tanh                                                                       |   | $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$                                                                       | $1 - f(x)^2$                                                                                                    | $(-1, 1)$           |
| Rectified linear unit (ReLU) [11]                                          |  | $\begin{cases} 0 & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases}$<br>$= \max\{0, x\} = x \mathbf{1}_{x>0}$ | $\begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x > 0 \\ \text{undefined} & \text{if } x = 0 \end{cases}$ | $[0, \infty)$       |

Şekil 4.3. Birkaç önemli aktivasyon fonksiyonunun grafiksel gösterimi (a) Sigmoid, (b) Tanh ve (c) RELU aktivasyon fonksiyonu

Bu bölüm, her bir aktivasyon fonksiyonunun detaylı açıklamasıyla devam etmektedir.

#### 4.3.1. Doğrultulmuş Doğrusal Birim (ReLU) Aktivasyon Fonksiyonu

ReLU aktivasyon fonksiyonu, hesaplama verimliliği ve "kaybolan gradyan" sorununu hafifletme kabiliyeti nedeniyle DL'de yaygın olarak kullanılan doğrusal bir aktivasyon fonksiyonudur. Pozitifse giriş değerini, aksi takdirde 0 değerini döndürerek daha hızlı hesaplama ve verimli gradyan yayılımı sağlar. "ReLU Doygunluğu" probleminden muzdarip olmasına rağmen, Sızdıran ReLU ve ELU gibi varyantlar bu sınırlamayı ele alır. ReLU, basitliği, yorumlanabilirliği ve DL'deki karmaşık görevleri ele alma yeteneği nedeniyle yaygın olarak kullanılmaktadır. ReLU'nun matematiksel formu (4.5)'de açıklanmıştır.

$$f(x) = \max(0, x) \quad (4.5)$$



Burada,  $x$  fonksiyonun girdisini temsil eder ve  $f(x)$  çıktıdır. ReLU fonksiyonu, pozitif (sıfırdan büyük veya sıfıra eşit) olması durumunda giriş değerini döndürür ve herhangi bir negatif giriş için 0 döndürür.

#### 4.3.2. Sigmoid Aktivasyon Fonksiyonu

Denklem (4.6)'da gösterilen sigmoid aktivasyon fonksiyonu, ANN ve DL problemlerinde olasılıkları temsil etmek için yaygın olarak kullanılan doğrusal olmayan bir aktivasyon fonksiyonudur, ancak ağıın öğrenmesini zorlaştıran "kaybolan gradyan" probleminden etkilenmiştir (Srinivasan & Ramalingam Balamurugan, 2022).

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4.6)$$

"Kaybolan gradyan" sorunu, sigmoid fonksiyonunun 0 ile 0,25 arasında olan türevlerinden kaynaklanır ve DL'de yavaş öğrenmeye veya hiç öğrenmemeye yol açabilir. Bu sorunun üstesinden gelmek için araştırmacılar ReLU, Leaky ReLU ve ELU gibi sıfır olmayan türevlere sahip olan ve ağıın öğrenme performansını artıran diğer aktivasyon fonksiyonlarının kullanılmasını önermişlerdir.

#### 4.3.3. Hiperbolik Tanjant Aktivasyon Fonksiyonu

Tanh (hiperbolik tanjant) aktivasyon fonksiyonu sigmoid benzeri doğrusal olmayan bir aktivasyon fonksiyonudur, girişi belirli bir aralığa, bu durumda -1 ile 1 arasına eşler. Tanh genellikle ANN'ların veya DL ağlarının gizli katmanlarında kullanılır. Ağıın daha kolay eğitilmesini sağlayan daha dik gradyanı nedeniyle sigmoid fonksiyonuna göre tercih edilir (Srinivasan & Ramalingam Balamurugan, 2022). Daha dik gradyan, öğrenme süreci sırasında daha hızlı yakınsama sağlayarak ağıın daha verimli bir şekilde öğrenmesini sağlar. Tanh aktivasyon fonksiyonunun matematiksel formu (4.7)'de sunulmuştur.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.7)$$

Önerilen çalışmada, LSTM modeli için aktivasyon fonksiyonu olarak hiperbolik tanjant (tanh) aktivasyon fonksiyonu kullanılmıştır. Doğrusal olmama ve hücre durumu boyunca bilgi akışını kontrol etme normalde bu aktivasyon fonksiyonu kullanılarak LSTM ağlarında gerçekleştirilir. Giriş değerlerini  $[-1, 1]$  aralığına eşleyen tanh

aktivasyon fonksiyonu ile kaybolan gradyan sorunundan kaçınılır. Bu, LSTM hücrelerini zaman içinde bilgi edinmek ve saklamak için ideal hale getirir.

#### 4.4. LSTM Ağının Hiperparametreleri

Hiperparametreler, ağ yapısını ve LSTM ağının eğitimini belirleyen değişkenlerdir. LSTM hiper parametreleri (örneğin hücre sayısı, katmanlar, öğrenme oranı, blok boyutu ve dizi uzunluğu) zaman serisi tahmini için çok önemlidir. Hiper parametreler model karmaşıklığına, yakınsamaya ve sabitlenebilirliğe bağlıdır ve bu nedenle tahmin doğruluğu üzerinde doğrudan bir etkiye sahiptir. Hiper parametrelerin uygun şekilde ayarlanması, eğitim sürecini ve önerilen LSTM tabanlı MPPT modelinin tahmin kapasitesini etkiler. Bu bölüm, önerilen LSTM ağında kullanılan hiper parametrelerin kısa bir açıklamasına doğru ilerlemektedir. Önerilen LSTM'de kullanılan hiper parametreler **Çizelge 4.1**'de listelenmiştir.

**Çizelge 4.1.** Önerilen LSTM'de kullanılan hiperparametrelerin listesi

| Değişkenin Adı           | Değer      |
|--------------------------|------------|
| Ağ Türü                  | Stack LSTM |
| Katman Sayısı            | 2          |
| LSTM Ünitesinin Türü     | Stack      |
| Nöron Sayısı             | 64, 32     |
| Toplu İş Büyüklüğü       | 32         |
| Dönem Sayısı             | 50         |
| Öğrenme Oranı            | 0.05       |
| Aktivasyon Fonksiyonları | Tanh       |

Zaman serisi tahmini için bir LSTM ağı tasarlarken, hiper parametreler ağın performansını belirlemede çok önemli bir rol oynar. Bir LSTM ağının tasarımında yer alan hiper parametrelerden bazıları ağ tipi, katman sayısı, LSTM birimi tipi, nöron veya LSTM hücresi sayısı, stack boyutu, epok sayısı ve öğrenme oranını içerir. Hiper parametrelerin kısa açıklaması aşağıda vurgulanmıştır ve önerilen LSTM modelinde kullanılan tüm parametrelerin ayrıntıları LSTM ağının eğitiminin eğitim seçenekleri alt bölümünde açıklanmıştır.

- Veri hazırlama sürecini etkilediği için ağ türünün seçilmesi önemlidir. Bu çalışmada, MPPT görevini yerine getirmek için stack LSTM düşünülmüştür.

- Gizli katman sayısının seçimi, problemin karmaşıklığına bağlıdır. Karmaşık girdilere sahip karmaşık modeller, doğruluğu artırmak için çoklu gizli katmanlara ihtiyaç duyar. Bu çalışmada, girdiler ve hedef için büyük veri (1 milyon) dikkate alınmıştır, bu nedenle model iki LSTM katmanlarını kullanmıştır.
- Her katmandaki nöron veya LSTM hücrelerinin sayısı ağıın performansını etkileyebilir. Daha fazla sayıda nöron ağıın doğruluğunu artırır ancak diğer yandan hesaplama süresini artırır. Bu çalışmada, ilk gizli katmanda 64, ikinci katmanda 32 nöron dikkate alınmıştır.
- Stack boyutu, model güncellenmeden önce işlenen örnek sayısını ifade eder. stack boyutu ne kadar büyük olursa doğruluk o kadar artar, ancak daha fazla bellek gerektirir ve hesaplama karmaşıklığını artırır. Daha küçük bir stack boyutu daha az bellek tüketirken, aynı zamanda yavaş yakınsamaya sahiptir ve doğruluğu da daha düşüktür.
- Epok sayısı, modelin tüm veri kümesi üzerinde toplam kaç kez eğitildiğini ifade eder. Çok sayıda epok, modelin verileri birçok kez görmesine yardımcı olur ve model yeni girdilere kolayca genelleme yapabilir, ancak çok sayıda epok da aşırı uyum sorunlarıyla karşı karşıyadır. Öte yandan, küçük bir epok zaman ve bellek tasarrufu sağlar, model doğruluğu da azalır çünkü model tüm veriyi daha kısa sürede görür.
- Öğrenme oranı, hedef çıktıyı tahmin etmek için eğitim sırasında modelin güncellendiği adım boyutudur. Daha küçük öğrenme oranı daha yüksek doğruluğa yol açar, ancak eğitim süresini artırır. Daha büyük öğrenme oranı hızlı eğitim sunarken aynı zamanda doğruluğu da azaltır (Jepkoech et al., 2021).
- Aktivasyon fonksiyonunun seçimi, ağıın performansını ve zaman serisi verilerindeki karmaşık ilişkileri modelleme yeteneğini önemli ölçüde etkileyebilir (Farzad et al., 2019). Bu çalışmada, gradyan kaybolma problemleriyle başa çıkabilen tanh aktivasyon fonksiyonu kullanılmıştır.

#### 4.5. LSTM Ağının Türleri

LSTM ağları uzun vadeli bağımlılıkları yakalama avantajına sahiptir ve bu nedenle dizileri tahmin etmek için etkili bir yöntemdir. Girdi örüntüleri, ters bağımlılıklar ve

hesaplama gereksinimleri gibi faktörlere bağılı olarak farklı LSTM türleri vardır. Aşağıdaki bölüm, çeşitli uygulamalar için farklı LSTM ağı tasarımlarını vurgulamaktadır:

#### 4.5.1. Tek katmanlı LSTM

Tek katmanlı LSTM mimarisi, sonuçları tahmin etmek için yalnızca bir gizli ve bir çıkış katmanından oluşur. Bu temel tasarım genellikle duygu analizi, dil modelleme veya basit zaman serisi tahmini gibi görevler için kullanılır.

#### 4.5.2. Stack LSTM

Bir listeyi veya birden fazla LSTM katmanını sıkıştıran LSTM ağı modeli Stack LSTM mimarisidir. Derin LSTM Ağı Modeli, Stack LSTM Ağı Modeli olarak da bilinir. Bu mimaride, tek bir çıktı değeri tahmin etmek yerine, her LSTM katmanı başka bir LSTM katmanına gönderilmek üzere bir dizi çıktı tahmin eder. Bundan sonra, son LSTM katmanı tarafından tek bir çıktı tahmin edilir.

Stack LSTM'ler iki LSTM katmanlı görevlerde kullanılır ve uygulamaları zaman serisi tahmini, konuşma tanıma, makine çevirisi veya video analizi için geçerlidir.

#### 4.5.3. Çift Yönlü LSTM

Bu mimaride, giriş dizisi hem ileriye hem de geriye doğru işlenerek eski ve yeni bağlamlardan eşzamanlı veri toplanması sağlanır. Çift yönlü LSTM mimarisi, soldan sağa doğru ileri yönler için bir LSTM ve soldan sağa doğru geri yönler için başka bir LSTM yerine iki LSTM'ye dayanmaktadır.

Bu mimari, ağa geleneksel bir LSTM'den daha fazla bağlam bilgisi sağlayabilir çünkü sol ve sağ olmak üzere her iki taraftaki kelimeler hakkında veri toplayabilecektir. Sıralama ile ilgili sınıflandırma problemlerinin performansı hızlanacaktır.

Çift yönlü LSTM, zaman serisi tahmini, konuşma tanıma, varlıkların isimleri ve duygu analizi gibi görevler için zaten uygulanmıştır.

#### 4.5.4. CNN-LSTM

CNN LSTM mimarisi hem CNN hem de LSTM mimarilerinden oluşmaktadır. Temel özellikleri girdiden almak ve bunları dizi tahmini için kullanılabilmeleri amacıyla LSTM katmanına göndermek için bu mimari bir CNN ağ katmanı kullanır.

#### 4.5.5. Dikkat tabanlı LSTM

Dikkat mekanizmaları, işleme sırasında farklı girdi öğelerinin önemini dinamik olarak tartmak için LSTM ağlarına eklenir. Bu tasarım, makine çevirisi, resim altyazısı veya belge özetleme gibi görevlerde performansı artırır.

#### 4.5.6. Multimodal LSTM

Metin, görüntü veya ses gibi birden fazla girdi verisi modalitesinin LSTM mimarisine dahil edilmesi, ağın aynı anda farklı bilgi kaynaklarından öğrenmesini sağlar. Multimodal LSTM'ler, multimodal duygu analizi veya multimodal makine çevirisi gibi görevlerde performansı artırır.

Bu tez, tek katmanlı LSTM, çift yönlü LSTM, CNN-LSTM, çok modlu LSTM ve geleneksel makine öğrenimi teknikleri gibi diğer yöntemlere kıyasla uzun vadeli bağımlılık modelleme ve tahmin doğruluğunu artırmak için stack LSTM ağlarını kullanmaktadır. Çok katmanlı mimari, stack LSTM'nin birden fazla tarihsel faktörün çıktıları etkilediği PV verilerindeki karmaşık zamansal ilişkileri öğrenmesine olanak tanır. Stack LSTM, karmaşık zaman serisi bağımlılıklarını yakalamada tek katmanlı tek yönlü LSTM'den daha iyi performans gösterir (Khumaidi et al., 2020). Derinlik ayrıca CNN-LSTM veya multimodal LSTM'den daha güçlü temsili öğrenme sağlar. Bununla birlikte, karmaşıklık düzenlileştirme, artan eğitim süresi ve aşırı ezber riski gerektirir. LSTM'deki stack katmanlarının artırılması korelasyon modellemesini ve zaman serisi tahminini iyileştirir, ancak verimlilik ve bellek karmaşıklığı da dikkate alınmalıdır.

#### 4.6. Önerilen Stack LSTM Ağı

Bu tezde, uzun vadeli karşılıklı bağımlılığı simüle edebilen ve doğru tahminler yapmak için karmaşıklığı kullanabilen stack LSTM ağı kullanılmıştır. Uzun vadeli

dizileri başarıyla yakalayan ve temsil kabiliyetini artırmak için çok katmanlı yapıdan yararlanan stack LSTM'lerin kullanımı, PV sistemlerinin tahminlerini iyileştirmek için seçilmiştir. Bu çalışmanın amacı, MPPT PV güneş enerjisi çıkarımında mükemmel performans elde etmek için stack LSTM'ler oluşturmak ve bunların temsili niteliklerinden yararlanmaktır. Önerilen stack LSTM yaklaşımı, diğer LSTM yaklaşımlarına göre çeşitli avantajlar sunduğu için aralıklı T ve G verilerinin varlığında solar PV dizisinin MPP'sini çıkarmak için kullanılır. Stacked LSTM yaklaşımının bir MPPT denetleyicisi olarak avantajları aşağıda gösterilmiştir:

#### **4.6.1. Geliştirilmiş Model Performansı**

Bilgi dizilerini tahmin etmek için, stack LSTM'lerin güneş enerjisi tahmini ve öngörüsü alanında daha iyi performans gösterebildiği gösterilmiştir. Buna ek olarak, stack LSTM modelinin çoklu gizli katmanları, giriş verilerinin (G, T) daha karmaşık bir şekilde temsil edilmesine olanak tanıyarak güneş enerjisi üretiminin tahmininde doğruluğun artmasını sağlar.

#### **4.6.2. Uzun Vadeli Bağımlılıkların Yakalanması**

Doğru solar üretim tahminleri için gerekli olan LSTM'ler, zaman serisi verilerindeki uzun vadeli zamansal bağımlılıkları yakalayabilir. Bir LSTM stack modelindeki birden fazla katmanla, ağ uzun bir zaman ufkundaki kalıpları tespit edip hatırlayabilir ve daha doğru tahmin yapmasına olanak tanır.

#### **4.6.3. Hiyerarşik Temsil**

Çeşitli soyutlama seviyeleri ve 1 milyon veri noktası içeren girdi verilerinin (G, T) temsilleri, LSTM stack modelinin her katmanı tarafından öğrenilir. Düşük seviyeli özellikler en alt katmanlar tarafından yakalanırken, daha soyut ve karmaşık modeller üst katmanlar tarafından yakalanır. Bu temsil hiyerarşisi, modellerin çeşitli ayrıntı düzeylerinde gerekli bilgileri çıkarmasını ve kullanmasını sağlayarak MPP çıkarma performansını artırır.

#### 4.6.4. Esneklik ve Uyarlanabilirlik

Stack LSTM, model mimarisi açısından esneklik sunar ve eldeki sorunun özel gereksinimlerine uyacak şekilde kolayca özelleştirilebilir. LSTM katmanlarının sayısı ve her katmandaki bellek hücrelerinin sayısı, veri kümesinin karmaşıklığına ve istenen doğruluk düzeyine göre ayarlanabilir.

#### 4.7. Solar PV Sistemi İçin MPPT Olarak LSTM Stack


Şebekeye bağlı 100 kW solar PV sistemi için LSTM tabanlı MPPT kontrolörünü entegre etmek olan önerilen araştırmanın temel amacı göz önüne alındığında. PV sistemlerine genel bakış, bir MPPT kontrolörüne duyulan ihtiyaç, LSTM MPPT'nin geleneksel algoritmalara göre avantajları ve önerilen LSTM MPPT kontrolörünün karşılaştırılması bu alt bölümde vurgulanmaktadır. LSTM'nin MPPT kontrolörü olarak uygulanmasına geçmeden önce, bir PV sistemindeki MPPT kontrolörü kavramı kısaca açıklanmaktadır. Daha sonraki alt bölüm LSTM'yi MPPT kontrolörü olarak entegre etme konseptine doğru ilerlemektedir. Solar PV sistemi, MPPT kontrolörü ve IV-PV özelliklerinin ayrıntılı açıklaması **3. bölümde** zaten açıklanmıştır. Bu alt bölüm sadece MPPT'nin temel kavramını vurgulamakta ve daha sonra önerilen stack LSTM'nin MPPT kontrolörü olarak entegrasyonuna doğru ilerlemektedir.

##### 4.7.1. Önerilen Solar PV Sistemine Genel Bakış

LSTM DL algoritmasının önemi, daha yüksek doğruluğu ve düşük tahmin hatası göz önüne alındığında, bu araştırma MATLAB 2023© kullanarak 100 kW şebekeye bağlı bir solar PV sistemi için LSTM tabanlı bir MPPT kontrolörü tasarlamıştır. Önerilen sistemin tam şematik diyagramı **Şekil 4.4**'te gösterilmektedir.

Bu bağlamda, maksimum 100,2 kW PV çıkışına sahip SunPower TS-SPR-315 PV modülü dikkate alınmıştır. G ve T Standart Test Koşullarında (STC), dizi başına 5 seri bağlı modül ve 65 paralel bağlı dizi, yaklaşık 100 kW olan 99,87'lik istenen çıkış gücünü verir. Amaç, stack bir LSTM MPPT denetleyicisi kullanarak değişken girişlerin (T ve G) varlığında PV dizisinin bu maksimum gücünü elde etmektir. Önerilen modelde, PV dizisi, MPPT kontrolörü, yükseltici tip DC-DC dönüştürücü ve inverter kontrol stratejisi araştırmanın önemli parçalarıdır. Bu alt bölüm, aynı zamanda MPPT denetleyicisinin

girdileri olan PV dizisi için giriş dizisi verilerinin oluşturulmasını takiben PV dizisi spesifikasyonunun tasarımı ile devam etmektedir. PV dizinin çıkış voltajı, yükseltici tip DC-DC dönüştürücünün giriş voltajını verir ve MPPT kontrolörünün çıkışı, anahtarlar için bir kontrol sinyali görevi görür.



Şekil 4.4. Önerilen araştırmada şebekeye bağlı PV dizisinin birinci ve ikinci aşamalarını da gösteren eksiksiz şematik diyagram.

#### 4.7.1.1. PV Dizisinin Tasarım Parametreleri

PV tasarım parametreleri, söz konusu PV dizisinin özelliklerini açıklar. Bu özellikler, PV sisteminin davranışının modellenmesi ve değerlendirilmesinde kritik öneme sahiptir. Önerilen PV sisteminin tasarım parametreleri Çizelge 3.1'de listelenmiştir. Ana parametrelerin kapsamı ve önemi aşağıda açıklanmaktadır.



- **Seri ve Paralel Bağlı PV Modüller**

$N_{series}$  ( $N_s$ ) ve  $N_{parallel}$  ( $N_p$ ) değerleri sırasıyla sistemdeki seri bağlı ve paralel bağlı PV modüllerinin sayısını gösterir. Bunlar PV sistemin toplam gerilim ve akım değerlerini belirler. Bu değişkenler, toplam PV modül sayısını tahmin etmek ve şebekeye elektrik bağlantıları kurmak için gereklidir. PV modüllerin seri ve paralel olarak yerleştirilmesi sistemin gerilim ve akım seviyelerini etkileyerek performansını ve verimliliğini etkiler. Önerilen modelde, istenen 100 kW çıkış gücünü elde etmek için dizi başına 5 seri bağlı modül ve 65 paralel dizi bağlanmıştır. Daha fazla sayıda paralel modül, güç üretimini artıran büyük akım üretirken, daha az sayıda seri modül, belirli inverterlere daha uygun olan ve güvenliği artıran daha düşük voltaj üretir. Bu kombinasyon sistemin genel verimliliğini, uyarlanabilirliğini ve performansını artırır.

- **Kısa Devre ve MPP Akımı**

Bir PV sisteminde  $I_{sc}$  ve  $I_{mp}$  kritik parametrelerdir.  $I_{sc}$  kısa devre akımı içindir ve güvenlik nedenleriyle önemli olan kısa devre sırasında maksimum akım akışını tanımlar. Öte yandan  $I_{mp}$ , maksimum güç noktası akımıdır ve belirtilen koşullar altında maksimum güç çıkışını ifade eder. Bu değişkenlerin anlaşılması, güvenlik cihazlarının boyutlandırılmasına ve sistemin çeşitli koşullardaki davranışının tanımlanmasına yardımcı olur. Önerilen PV modülünün kısa devre değeri 5,95 A'dir.

- **Açık Devre ve MPP Gerilimi**

$V_{oc}$  ile  $V_{mp}$  bir PV sisteminin temel kontrol değişkenleridir.  $V_{oc}$ , maksimum voltaj çıkışını gösteren açık devre voltajıdır,  $V_{mp}$  ise maksimum güç noktasındaki voltajdır. Bu değerler sistemin çalışma aralığının belirlenmesine, uygun güç elektroniği bileşenlerinin seçilmesine ve gerilim-akım eğrisi kullanılarak sistemin davranışının analiz edilmesine yardımcı olur. Tek bir PV hücresi için açık devre gerilimi ( $V_{oc}$ ), önerilen PV modülünün teknik özelliklerinde belirtildiği gibi 64,2V olarak kabul edilir.

- **Gerilim ve Akımın Sıcaklık Katsayısı**

Denklem (4.11)'de kullanılan dengeleme faktörleri ( $\alpha$ ,  $\beta$ ), sırasıyla sıcaklığın PV modül voltajı ve akımı üzerindeki etkisini açıklayan sıcaklık katsayılarıdır. Bunlar, gerçek dünyadaki sıcaklık dalgalanmalarını dikkate alırken PV sisteminin verimliliğini doğru bir şekilde ortaya koymak için önemlidir. Sistem modelleme ve analizinde, bu katsayılar PV modül özelliklerindeki sıcaklığa bağlı değişiklikleri hesaplamak için kullanılır.

#### 4.7.1.2. Girdi ve Hedef Veriler için Model Formülasyonu

G verileri National Renewable Energy Laboratory (NREL), European Solar Radiation Atlas ve World Radiation Data Centre (WRDC) gibi farklı kaynaklarda mevcuttur ve coğrafi konuma göre 0 ile 1000 W/m<sup>2</sup> arasında değişmektedir. Yukarıdaki kaynaklardan elde edilen veri noktalarını ve ilgili sınırları analiz ettikten sonra, bu çalışma (Roy et al., 2021)'deki yazarlar tarafından önerildiği gibi (4.8) ve (4.9) denklemlerini kullanarak G ve T'nin çoğaltılmış verilerini oluşturmuştur.

$$G = [(G_{max} - G_{min}) \times rand] + G_{min} \quad (4.8)$$

$$T = [(T_{max} - T_{min}) \times rand] + T_{min} \quad (4.9)$$

G seviyesi PV çıkış gücü ile doğru orantılıdır ve T, PV dizisi tarafından üretilen çıkış gücü ile ters orantılıdır. Bir PV sisteminde  $V_{mp}$ , ilgili T ve G değerlerini takiben PV panelinin maksimum gücünü verir. Giriş (G, T) verilerine ek olarak, denetimli DL (stack LSTM) ağını eğitmek için  $V_{mp}$  için başlangıç hedef verileri de gereklidir. Yazarlar (Srinivasan & Ramalingam Balamurugan, 2022), yalnızca T girişine bağlı olan denklem (4.10)'ü kullanarak hedef verileri oluşturmuştur.

$$V_{mp} = V_{mp(STC)} + \beta(T_s - T) \quad (4.10)$$

Bu nedenle, bu çalışmada (4.10) numaralı denklem, Simulink MATLAB'da SunPower TS-SPR-315 PV modülü kullanılarak T ve G'nin farklı değerlerine karşı  $V_{mp}$ 'nin hedef yanıtı manuel olarak toplanarak değiştirilmiş ve daha sonra bu değerler kullanılarak PV modülünün  $\alpha$  ve  $\beta$  değerleriyle de eşleşen sabit değerleri elde etmek için LSQRT doğrusal regresyon uygulanmıştır. LSTM'nin ilk eğitimi için önerilen  $V_{mp}$  denklemi (4.11)'de modellenmiştir ve MPPT kontrolörünün hem G hem de T girişine bağlıdır. PV akımı için denklem (4.12)'de modellenmiştir.

$$V_{mp} = V_{mp(STC)} + \beta(K * T - T_s) + \alpha(1 + G) \quad (4.11)$$

$$I_{mp} = \left\{ I_{mp(STC)} + \left[ \frac{G}{G_s} (1 + \alpha(T - T_s)) \right] \right\} \quad (4.12)$$

$$P_{mp} = \{V_{mp} * I_{mp}\} \quad (4.13)$$

Denklem (4.13)'te MPP'deki akım ve gerilimin çarpımı olan güç modellenmiştir. (4.8)'den (4.13)'e kadar olan denklemler önerilen LSTM MPPT kontrolörünün girdileri ve hedef formülasyonu için kullanılmış ve değişkenlerin değerleri PV dizisinin kullanılan diğer parametreleriyle birlikte **Çizelge 3.1**'de sunulmuştur. Daha sonra, T ve G'nin bu giriş verileri, önerilen PV dizisi için önerilen bir MPPT denetleyicisi olarak kullanılan önerilen stack LSTM'yi eğitmek ve test etmek için kullanılacaktır. Hedef değer ( $V_{mp}$ ), PV dizisinin veya MPPT denetleyicisinin her iki girişine (T ve G) bağlıdır. G değeri ne kadar yüksek olursa  $V_{mp}$  değeri de o kadar yüksek olur. Daha yüksek T değeri ise  $V_{mp}$  değerini düşürür.

#### 4.7.2. Solar PV Sisteminde MPPT'ye Genel Bakış

Solar PV enerjisi, G ve T parametrelerindeki hızlı değişimler nedeniyle düşük enerji dönüşüm verimliliği (%10-25) ve enerji çıkışı sergilemektedir. Bu hızlı dalgalanmalar akım, gerilim ve güçte salınımlara neden olarak güneş enerjisinin şebeke ile entegrasyonunda zorluklar yaratmaktadır (El-Khozondar et al., 2016). PV panellerin T ve G değişimlerine göre PV karakteristikleri **Şekil 3.8**'de sunulmuştur. MPP'deki gerilim ( $V_{mp}$ ), PV panelin maksimum güç ürettiği çalışma noktasını temsil etmektedir. G'deki değişiklikler  $V_{mp}$  üzerinde minimum etkiye sahipken, T'deki değişikliklerin değeri üzerinde büyük bir etkisi vardır (Esrām ve Chapman, 2007). MPP'deki voltaj ( $V_{mp}$ ), PV panelin maksimum güç ürettiği çalışma noktasını temsil eder.

PV enerjisi, ışıınım ve sıcaklıktaki hızlı değişimler nedeniyle düşük enerji dönüşüm verimliliği (%10-25) ve enerji çıkışı sergilemektedir. Bu hızlı dalgalanmalar akım, gerilim ve güçte salınımlara neden olmakta ve şebeke ile solar PV entegrasyonunda zorluklar yaratmaktadır. PV panellerinin T ve G değişimlerine göre P/V karakteristikleri sırasıyla Şekil 3.8 (a) ve (b)'de sunulmuştur. MPP'deki ( $V_{mp}$ ) gerilim, PV panelin maksimum gücü ürettiği çalışma noktasını temsil eder (Esrām & Chapman, 2007). G'deki değişiklikler  $V_{mp}$  üzerinde minimum etkiye sahipken, T değişikliklerinin değeri üzerinde büyük bir etkisi vardır.

Bir PV panelin güç çıkışını en üst düzeye çıkarmak için, yazarlar tarafından (Podder et al., 2019; Ram et al., 2017) belirtildiği gibi, PV panelin  $V_{mp}$ 'sini başarılı bir şekilde yöneten uygun bir MPPT tekniğinin uygulanması gerekmektedir. PV sistem, verimli bir MPPT tekniği kullanarak güç çıkarımını iyileştirir ve değişen çevresel koşullara tepki verir, böylece PV sistemin genel performansını ve enerji verimliliğini en üst düzeye çıkarır.

#### 4.8. MPPT Kontrolörü Olarak Önerilen Stack LSTM

Bu araştırmada, stack LSTM ağ mimarisi kullanan yeni bir MPPT yöntemi önerilmiştir. Şekil 6, önerilen sistemin tüm şematik diyagramını göstermektedir. Sabit adım boyutu, MPP etrafındaki salınımlar ve P&O, IC gibi geleneksel yaklaşımların yavaş izleme hızı, LSTM MPPT denetleyicisi ile aşılmaktadır (M. Sabri & Hassouni, 2022). Stack LSTM, ileri beslemeli DNN ve RNN ile karşılaştırıldığında, üstün uzun vadeli bağımlılık modellemesi, artan temsil gücü ve gelişmiş tahmin doğruluğu sunar.

Önerilen stack LSTM MPPT kontrolörü, girişler (G, T) ve hedef ( $V_{mp}$ ) veri kümesi arasındaki karmaşık korelasyonları etkili bir şekilde öğrenir. Giriş özellikleri T ve G iken,  $V_{mp}$  hedef çıktıdır. Modelimizin MPP'deki gerilimi doğru bir şekilde tahmin etme kapasitesi, operasyonel PV dizisi verileri üzerinde eğitim ile kolaylaştırılmıştır. Bu çalışmada sunulan yaklaşımda, PI denetleyici ile birlikte MPPT'nin çıkışı, yazarlar tarafından önerildiği gibi yükseltici tip DC-DC dönüştürücünün bir IGBT anahtarını kontrol etmek için kullanılır (KARABİNAOĞLU et al., 2022). Sonuç olarak, PV sistemi MPPT çıkarımı için öngörülen MPP voltajında PWM kontrolü kullanılarak çalıştırılabilir. Önerilen stack LSTM MPPT stratejisi, iki aşamalı şebekeye bağlı çift mimaride gelişmiş enerji hasadı için güneş enerjisini etkili bir şekilde yakalar.

LSTM ağı tabanlı MPPT kontrolörü, geleneksel tekniklerin yanı sıra ANN yöntemlerine göre çeşitli avantajlar sunmaktadır. LSTM modeli, P&O ve IC'yi etkileyen sabit adım boyutu, MPP etrafında salınım ve yavaş izleme gibi sorunları azaltır (M. Sabri & Hassouni, 2022). Ayrıca, ileri beslemeli ve RNN gibi ANN yöntemlerinin karşılaştığı uzun eğitim süresi, aşırı uyum, kaybolan gradyan gibi sorunları da önler (Los, n.d.). LSTM, bellek hücresi mimarisi sayesinde PV verilerindeki uzun vadeli zamansal bağımlılıkları yakalayabilir (Mohammed Sabri & El Hassouni, 2022). Bu, PV dizisinin doğrusal olmamasına rağmen MPP'nin doğru ve hızlı bir şekilde izlenmesini sağlar. Ek

olarak, önerilen LSTM, sıralı öğrenme yetenekleri nedeniyle değişen çalışma koşullarına iyi genelleme yapar.

#### 4.9. LSTM'yi Geleneksel MPPT ile Karşılaştırma

Bu bölüm, ilk olarak önerilen yığılmış LSTM'nin diğer MPPT ağlarına göre avantajlarını vurgulayarak ve ardından önerilen LSTM'nin geleneksel tekniklerle karşılaştırılmasıyla devam etmektedir.

LSTM-MPPT kontrolörünün P&O, IC, FLC ve ANN dahil olmak üzere geleneksel ve akıllı MPPT yöntemlerine göre birçok önemli avantajı vardır. Aşırı eğitim, kaybolan gradyanlar ve sabit adım boyutu gibi ilişkili sorunların üstesinden gelerek daha güvenilir ve verimli performans sağlar. LSTM mimarisinin dahili bellek özellikleri ve kapı yapısı da MPP'nin doğru bir şekilde izlenmesine olanak tanıyarak değişen çevresel koşullar ve PV dizisindeki doğrusal olmayan durumlar için esnekliği artırır. Bu niteliklerin bir sonucu olarak, LSTM-MPPT kontrolörü, solar PV dizisinin maksimum gücünü elde etmek için uygun ve üstün bir seçenektir.

LSTM ağının yüksek doğruluğu, performansı ve verimliliği göz önüne alındığında, çeşitli araştırmalar geleneksel ve akıllı ANN modelleri yerine DL modellerini tercih etmiştir. Yazarlar tarafından (Forootan et al., 2022)'de analiz edilen geleneksel ve akıllı MPPT kontrolörleri yerine derin ağ kullanılarak MPPT kontrolörünün değişken ortamdaki izleme doğruluğu ve verimliliği artırılabilir. Tek LSTM gücü, yazarlar tarafından önerilen kararlılık, yanıt verme ve maliyet etkinliği açısından ANN'ya hakimdir (Ozdemir et al., 2022; M. Sabri & Hassouni, 2022).

Tek katmanlı LSTM daha az karmaşık olmasına, daha az eğitim süresi sunmasına ve yığılmış LSTM'ye kıyasla daha düşük aşırı uyum riskine sahip olmasına rağmen, yığılmış LSTM'nin çoklu katmanları karmaşık ve büyük veri kümelerindeki ilişkiyi bulabilir, çoklu katmanlar uzun vadeli bilgileri depolamak için daha fazla bellek sunar ve bağımlılıkları yakalayabilir, bu da onları daha verimli hale getirir. Çift yönlü LSTM, geçmişten ve gelecekte bilgi tutma avantajı sunar, ancak aşırı uyum sorununa karşı en savunmasız olanlardır. Bununla birlikte, stack LSTM'nin sıralı yapısı bilgi akışını düzenler ve aşırı uyumu önler ve stack LSTM'nin çoklu katmanları da çift yönlü LSTM'den daha fazla bellek sunar. Benzer şekilde, stack LSTM, analiz edilen verilerin doğası nedeniyle zaman serisi veri tahmini veya öngörüsünde CNN-LSTM'den daha iyi performans gösterir. CNN-LSTM görüntü verileri için iyi performans gösterirken ve

verileri işlemek için konvolüsyon katmanları kullanırken, toplu LSTM zaman serisi veri tahmini için daha uygundur. Bununla birlikte, önerilen toplu LSTM'nin diğer tekniklere göre yukarıdaki avantajları göz önüne alındığında, önerilen zaman serisi verileri (MPP'deki T, G ve voltaj) için daha uygun ve verimli olmasını sağlar.

#### 4.10. LSTM Ağının Eğitimi

LSTM ağını eğitmeden önceki en önemli adımlar giriş ve hedef verilerinin toplanması ve ardından toplanan verilerin ön işlemden geçirilmesidir. Bu çalışmada, G ve T için giriş verileri sırasıyla (4.8) ve (4.9) kullanılarak toplanırken, hedef veriler (4.11) kullanılarak toplanmıştır. Veriler ön işleme tabi tutulmuş ve ortalama ve birim varyans ile standardize edilmiştir. Bu çalışmada, G ve T için girdi verileri sırasıyla (4.8) ve (4.9) kullanılarak toplanırken, hedef verileri (4.11) kullanılarak toplanmaktadır. Veriler önceden işlenir ve ortalama ve birim varyans ile standartlaştırılır. LSTM ağı girdiler (G, T) ve hedef ( $V_{mp}$ ) ile eğitilir. Dizin her biri 1 milyon (1.000.000) veri noktası (gözlem) içermektedir. Başlangıçtan itibaren, toplam veri kümesinin %80'i eğitim için kullanılır ve sondan kalan %20'lik kısım test ve doğrulama için kullanılır (H. Wang et al., 2022). LSTM ağ eğitimi yer alan adımlar Şekil 4.5'te gösterilmektedir.

Eğitim aşaması, makine öğrenimi ve derin öğrenme modellerinin geliştirilmesinde büyük önem taşımaktadır. Makine öğreniminde modeller, büyük veri kümelerine maruz bırakılarak eğitilir ve açık programlama olmadan görevleri yerine getirmeyi öğrenmeleri sağlanır (Forootan et al., 2022). Derin öğrenme algoritmaları, çeşitli ve yapılandırılmamış verilerden oluşan kapsamlı veri kümelerine dayanır. Eğitim verilerinin kalitesi, modelin performansını ve karar verme yeteneklerini büyük ölçüde etkiler. Eğitim sırasında modeller, eğitim matrisleri için rastgele değerlerle başlatılır ve bu ilk değerlere dayanarak çıktıyı tahmin etmeye çalışır. Başlangıçta, hata tipik olarak yüksektir, ancak yinelemeli ayarlamalar yoluyla, derin öğrenme algoritmaları hatalarından öğrenir, tahminleri ve ayarlamaları iyileştirir. Eğitimin birincil amacı, çeşitli sorguları ele almada yüksek düzeyde doğruluk gösteren son derece hassas bir model oluşturmaktır. Bir LSTM ağını eğitme ve test etme adımları Şekil 4.5'te özetlenmiştir (Malakar et al., 2021; M. Sabri & Hassouni, 2022; Mohammed Sabri & El Hassouni, 2022).

#### 4.10.1. Veri Ön İşleme

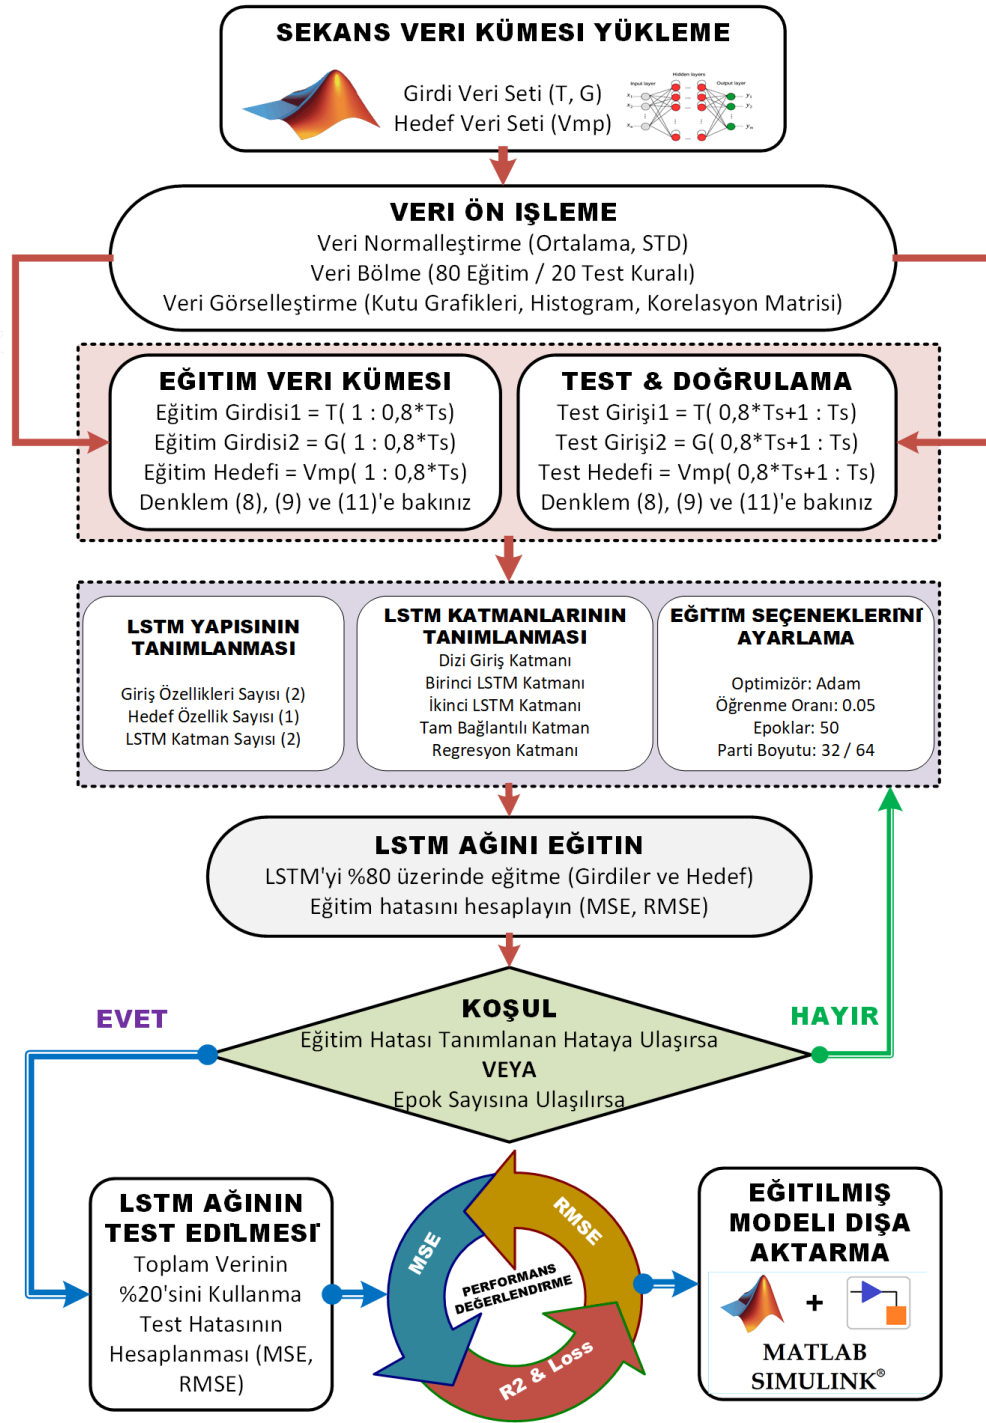
Girdi ve hedef verilerin oluşturulması ve yüklenmesinin ardından bu araştırma, verileri LSTM model eğitime hazırlamak için veri ön işleme süreçlerinin en önde gelen ve temel adımlarından birini ele almıştır (H. Wang et al., 2022).

Veri setinin kalitesini doğrulamak için, eksik değerler ilgili veri örneğinin ortalama değerleriyle dikkatlice doldurulmuş, veriler temizlenmiş ve aykırı değerler kaldırılmıştır. Ayrıca, LSTM modellerinin giriş özelliklerinden etkili bir şekilde öğrenmesi için gerekli olan verileri karşılaştırılabilir bir boyuta standartlaştırdık. Bu veri ön işleme işlemlerini yaparak LSTM ağının verilerdeki önemli örüntüleri ve bağımlılıkları yakalama kapasitesini artırdık. Bu da daha iyi yakınsama sağladı, ölçekle ilgili zorlukları azalttı ve LSTM modelinin temel bilgileri çıkarmasını sağlayarak güneş panelinin *Vmp* 'sini tahmin etmede gelişmiş doğruluk ve genelleştirme sağladı. Ön işleme için benimsenen ortak adımlar aşağıda vurgulanmıştır.

#### 4.10.2. Veri Toplama

NASA, NREL ve ESA gibi kaynaklardan alınan verileri ve kısıtlama limitlerini görselleştirdikten sonra, bu araştırma, (4.8) ve (4.9) denklemlerinde belirtildiği gibi verilen aralıklar dahilinde giriş verileri (T ve G) için rastgele sinyaller oluşturmak için MATLAB komut dosyası kullandı. Hedef veriler hem T hem de G değerlerinden etkilenen (4.11) kullanılarak oluşturulur. 100000 veri noktasından oluşturulan veri kümesinin tamamı, kolay depolama ve dağıtım için bir CSV dosyası olarak saklanır. Veriler, *csvread* veya *readmatrix* komutu gibi yöntemler kullanılarak MATLAB'a geri yüklenir ve verimli model eğitimi ve değerlendirmesine olanak tanır.

CSV dosyasının girdilerine ve hedef değerlerine erişim, modelin LSTM tabanlı regresyon performansının daha fazla araştırılmasını ve değerlendirilmesini sağlar. Bu diziler, LSTM ağını eğitmek ve test etmek için kullanılacak geçmiş verileri temsil etmektedir.



Şekil 4.5. Bir LSTM ağının eğitim sürecinin kontrol akışı

#### 4.10.2.1. Veri Normalizasyonu

LSTM model eğitimi için  $Vmp$  hedef değerlerinin Z-skor normalizasyonu gereklidir.  $Vmp$ 'nin -1,7 ila 1,7 arasında ölçeklendirilmesi hızlı yakınsama, gradyan



kararlılığı sağlar ve taşma/alt taşma sorunlarını önler. Ayrıca görünmeyen veriler için genelleştirmeye yardımcı olarak eğitim verimliliğini ve kararlılığını artırır. Tanh aktivasyon fonksiyonu, normalize edilmiş girdiler ve hedeflerle iyi çalıştığı ve eğitim sırasında daha yumuşak yakınsamayı kolaylaştırdığı için uygundur. Bu normalleştirme, modelin T ve G girdilerine dayalı olarak Vmp'yi doğru bir şekilde tahmin etmek için verilerden etkili bir şekilde öğrenmesini sağlar.

#### **4.10.2.2. Veri Setini Bölme**

Bir LSTM modelinin performansını değerlendirmek için, üretilen veriler iki kümeye ayrılır: eğitim verileri ve test verileri. Tipik olarak, yaygın bir uygulama, verilerin belirli bir yüzdesini (örneğin, %80) LSTM ağını eğitmek için ayırmak, kalan yüzdeyi (örneğin, %20) ise test ve doğrulama veri kümeleri arasında bölmektir (Khumaidi et al., 2020). Verilerin bölünmesi iki ana fayda sağlar; eğitim optimizasyon sunar ve test çalışmaları genelleme değerlendirmesine dayanır.

Eğitim verileri, modelin parametrelerini optimize etmek ve LSTM modeli eğitim süreci sırasında iç ağırlıklarını değiştirmek için kullanılır. LSTM modeli, tahmin edilen ve gerçek hedef değerler Vmp arasındaki boşluğu en aza indirmek için eğitim verilerinden öğrenir. Bu optimizasyon prosedürü, LSTM modelinin tahmin doğruluğunu artırmasına ve karmaşık veri bağımlılıklarını verimli bir şekilde dahil etmesine olanak tanır.

Test verileri, eğitilen LSTM modelinin görülmeyen çevresel koşullara ne kadar iyi genelleme yapabileceğini değerlendirir. Bilinmeyen çevresel koşullara genelleme yeteneği, modelin pratikte kullanılabilirliği açısından önemlidir. Eğitimli LSTM modelinin çeşitli gerçek dünya koşullarında sonuçları doğru bir şekilde tahmin edebilmesini sağlayarak onu güneş sistemlerinde veya başka herhangi bir uygulamada tahmin ve karar verme için güvenilir bir araç haline getirir. Bu nedenle, aşırı eğitimden ve bilinmeyen ortamlara genelleştirmeden kaçınmak için üretilen verileri eğitim ve teste bölmek gerekir.

#### **4.10.2.3. Eğitim için Veri Hazırlama**

Bu adımda, veriler LSTM model eğitimi için gereken formatta düzenlenir. Giriş ve hedef dizileri, verileri her satırın bir zaman adımını temsil ettiği ve her sütunun bir özelliğe karşılık geldiği sıralı bir biçime dönüştürmek için yer değiştirir. Bu değişiklik,

LSTM ağlarının verilerdeki zamansal ilişkileri ve örüntüleri tespit edebilmesi için gereklidir. Verilerin bu şekilde yapılandırılmasıyla, LSTM modeli geçmiş verilerden başarılı bir şekilde öğrenebilir ve girdilerin zaman serisi yapısına dayalı tahminler oluşturabilir. Verilerin sıralı formatta hazırlanması, LSTM modelinin geçmiş gözlemlere dayanarak kesin tahminler yapmasına olanak tanıyan kritik bir adımdır.

#### 4.10.2.4. Veri Görselleştirme

Normalleştirme, bölme ve eğitim için veri hazırlama işlemlerinin ardından, zaman serisi verilerinin çizilmesini, eğilimlerin, korelasyonların ve dağılımların keşfedilmesini ve LSTM ağının eğitimini ve performansını etkileyebilecek herhangi bir anormalliğin veya mevsimselliğin belirlenmesini içeren verilerin görselleştirilmesi adımı önemlidir. Bu çalışmada, girdiler ve hedef verilerden oluşan eksiksiz veri seti görselleştirilmekte ve bunu eğitim verileri, test verileri ve normalleştirme öncesi ve sonrası veriler gibi çeşitli diğer grafikler takip etmektedir. Veri görselleştirmeye dayalı sonuçların tamamı bir sonraki bölüm 5'te ele alınmaktadır.

#### 4.10.3. LSTM'nin Tanımlayıcı Yapısı

LSTM ağının yapısının tanımlanması, LSTM katmanlarının sayısının ve her katmandaki gizli birimlerin sayısının belirlenmesini içerir. Yapı, problemin karmaşıklığına ve gereksinimlerine bağlı olarak tam bağlantılı katmanlar veya çıktı katmanları gibi ek katmanlar da içerebilir.

##### 4.10.3.1. LSTM Katmanlarını Tanımlama

Ağ içindeki ayrı LSTM katmanları yapılandırılır. Her LSTM katmanı için aktivasyon fonksiyonları, düzenleme teknikleri (varsa) ve diğer hiper parametreleri belirtilir. Bu adım, LSTM ağının öğrenme dinamiklerini ve uyarlanabilirliğini kontrol etmeye yardımcı olur (Khumaidi et al., 2020). Bu araştırma, LSTM mimarisindeki LSTM katmanlarını tanımlamak için MATLAB'ın Derin Ağ Tasarımcısı Araç Kutusunu kullanmaktadır. PV sisteminin çevresel koşulları (T ve G) ve buna karşılık gelen hedef çıktı  $V_{mp}$ , zaman serisi verilerine örnektir ve önerilen LSTM katmanları, bu verilerdeki

karmaşık zaman serisi bağımlılıklarını işlemek ve öğrenmek için özellikle uygundur. LSTM katmanlarının mimarisi aşağıda açıklanmaktadır.

- **Giriş Katmanı (Dizi Giriş Katmanı)**

LSTM ağının ilk katmanı olan giriş katmanı, sıralı giriş verilerini almaktan sorumludur. Çalışmamızda bu katman çevresel girdiler olan T ve G'yi zaman serisi verisi şeklinde almaktadır. Giriş katmanında kullanılan özellik sayısı, bu araştırmada kullanılan giriş değişkenlerinin (T ve G) sayısına karşılık gelen 2 olarak belirlenmiştir.

- **LSTM Katmanı (Dizi Giriş Katmanı)**

LSTM katmanları, ağın zamansal bağlantıları ve örüntüleri tespit edebilmesini sağlayan temel unsurlardır. Bu çalışmada, LSTM tasarımının stack LSTM olarak bilinen ve birden fazla LSTM katmanını üst üste yığan bir çeşidi kullanılmıştır. Bu, modelin verilerin karmaşık bağımlılıklarını daha derinlemesine seçmesini sağlar ve tahmin edilen performansı artırır. Her bir LSTM katmanında ayarlanan gizli birim sayısı, ağın mevcut veri kümesinde bulunan karmaşık ilişkileri ne kadar iyi öğrenebileceğini ve temsil edebileceğini etkiler. Araştırmamızdaki ilk LSTM katmanında 64 gizli birim ve ikinci LSTM katmanında 32 gizli birim vardır ve ağın doğruluğu, 16 gizli birime sahip üçüncü bir LSTM katmanı eklenerek daha da geliştirilebilir. Bununla birlikte, daha yüksek sayıda LSTM katmanı sistemin yoğunluğunu, hesaplama süresini ve karmaşıklığını artırır.

- **Tam Bağlantılı Katman**

LSTM katmanlarından elde edilen çıktılar birleştirilir ve tam bağlı katman tarafından tek bir çıkış nöronuna eşlenir. Araştırmamızdaki tam bağlı katman, LSTM çıktılarını birleştirir ve öngörülen  $V_{mp}$  'yi temsil eden tek bir çıktı üretir.

- **Regresyon Katmanı**

Regresyon katmanı, öncelikle hedef verimiz  $V_{mp}$  gibi zaman serisi verilerinin tahmin edilmesi, öngörülmesi, izlenmesi gibi regresyon görevleri için oluşturulan LSTM ağının son katmanıdır. Eğitim sırasında, ağın farklılıklardan öğrenmesine ve performansı artırmasına yardımcı olmak için beklenen ve gerçek hedef  $V_{mp}$  arasındaki kaybı hesaplar.

#### 4.10.4. Eğitim Seçeneklerinin Yapılandırılması

Eğitim seçeneklerinin yapılandırılması, LSTM modelinin verimliliğini ve performansını doğrudan etkilediği için çok önemlidir.

**Çizelge 4.2.** Önerilen LSTM modelinin eğitimi için kullanılan eğitim seçenekleri

| Değişkenin Adı        | Değer  |
|-----------------------|--------|
| Çözücü                | Âdem   |
| İlk öğrenme oranı     | 0.005  |
| Maksimum dönemler     | 1000   |
| Sıra uzunluğu         | Uzun   |
| L2Düzenleme           | 0.0001 |
| Gradyan eşiği yöntemi | L2norm |
| Gradyan eşiği         | 1      |

Bu, optimizasyon algoritmasının (ör. Adam optimizer), kayıp fonksiyonunun (ör. ortalama karesel hata) ve öğrenme oranı, stack boyutu ve maksimum epok sayısı gibi diğer eğitim parametrelerinin tanımlanmasını içerir (Khumaidi et al., 2020). Bu seçenekler, eğitim sırasında LSTM modelinin yakınsamasını ve performansını etkiler. Önerilen stack LSTM modelinde kullanılan eğitim seçenekleri **Çizelge 4.2'**de listelenmiştir. DL modellerinin eğitim sürecinde, eğitim seçeneklerinin dikkatli bir şekilde özelleştirilmesi modelin parametrelerinin yapılandırılması için önemlidir. Bu adımda, önerilen çalışmada ( $T$ ,  $G$ ,  $V_{mp}$ ) verileri olan veri kümesi üzerinde modelin performansını artırmak için öğrenme prosedürü değiştirilir. Aşağıda eğitim seçeneklerinden bazıları verilmiştir:

- **Optimizasyon Algoritması (Adam Optimizer)**

Gerçek çıktı arasındaki tahmin hatasını en aza indirmek için, eğitim sırasında parametrelerin güncellemelerini belirlemek için optimizasyon algoritması kullanılır. Araştırmamızda, Adam optimize edicisi, uyarlanabilir öğrenme oranı, momentum, bias düzeltme ve uyarlanabilir ölçekleme yeteneği nedeniyle geleneksel stokastik gradyan inişine (SGD) tercih edilmiştir (Cocianu et al., 2022). Bu nedenle, LSTM ağırları bu optimize edici ile daha iyi optimizasyon ve daha hızlı yakınsama sağlar. Momentum ve bias düzeltme, optimizasyon ortamındaki düz alanlarda daha etkili hareket etmeye yardımcı olurken, uyarlanabilir öğrenme oranı bireysel parametre öğrenme oranlarını yönetir. Bu avantajlar nedeniyle, Adam optimize edicisinin çeşitli öğrenme oranlarını yönetme ve optimizasyon verimliliğini artırma kapasitesini de desteklemektedir.

- **Maksimum Epok Sayısı**

Maksimum epok sayısı, tüm veri kümesinin eğitim için güncellendiği geçiş sayısını veya sayısını ifade eder. Bu çalışmada, maksimum epok sayısı 50 olarak seçilmiştir, bu da LSTM modelinin tüm veri kümesi boyunca 50 kez yineleneceğini göstermektedir. Çok sayıda epok, gerçek ve hedef değer arasındaki hatayı azaltarak doğruluğu açıkça artırır, ancak aynı zamanda modelin karmaşıklığını ve hesaplama yoğunluğunu da artırır. Çok fazla sayıda epok da aşırı eğitmeye yol açabilir. Aşırı uyum sağlayan model aynı veri kümesini iyi bir şekilde ezberler ancak görülmeyen veriler üzerinde genelleme yapamaz.

- **Mini Grup Büyüklüğü**

Mini grup boyutu (mini batch size), modelin parametrelerini güncellemek için her iterasyonda kullanılan örnek sayısını tanımlar. Araştırmamızda, eğitim verimliliğini ve bellek kullanımını dengeleyen mini grup boyutunu 32 olarak belirledik. Bu çalışmada, 50 epok ve 30 mini grup boyutu ile toplam 1.000.000 veri noktası vardır, 1.000.000 veri noktası ve 30 mini grup boyutu ile 33.333 mini grup boyutu verecektir. Projenin bir parçası olarak model, her biri epok başına 30 veri örneği içeren 33.333 mini grup üzerinde çalışacaktır. Her mini grupten sonra modelin parametreleri ayarlanacak ve bu döngü 100 kez tekrarlanacaktır. Model, parametrelerini 30 mini grup boyutuyla etkili bir şekilde güncelleyebilir, bu da eğitim sırasında daha hızlı yakınsama ve daha verimli bellek kullanımı sağlar.

- **İlk Öğrenme Oranı**

Başlangıçtaki öğrenme oranı bir adım boyutu gibidir. Bu çalışmada öğrenme oranı 0,01 olarak kabul edilmiştir ve eğitim süreci boyunca parametreleri günceller. Adam optimize edici, belirlenen hedef değer gibi istenen tahmini çıktıyı elde etmek için eğitim sürecini optimize etmek üzere bu öğrenme oranını benimser.

- **Veri Karıştırma**

Eğitim sırasında verileri karıştırmak, LSTM modelinin veri örneklerinin sırasını ezberlemesini ve belirli kalıplara aşırı uyum sağlamasını önlemek için çok önemli bir stratejidir. Araştırmamızda her dönemden sonra verileri karıştırarak modele her dönemdeki verilere farklı bir bakış açısı kazandırıyoruz. Bu, modeli yeni görülmemiş veriler üzerinde performansı artıran daha güçlü, daha aktarılabilir kalıpları keşfetmeye iter.

- **Verbose Yapılandırması**

Çalışmamızda, kapsamlı eğitim ilerleme bildirimlerini görüntüleyen "Verbose" seçeneği "true" olarak ayarlanmıştır. Bu sayede eğitim sırasında modelin ilerleme durumu ve performansı görselleştirilebilmektedir. Birden fazla dönemle uzun eğitim oturumları çalıştırmak, çıktı istemini dolu ve yüklü tuttuğu için biraz dağınık hale gelir.

- **Grafiklerin Görselleştirilmesi**

Bu tezde, "Plots" seçeneği "training-progress" olarak ayarlanmış ve eğitimin ilerleyişini görmemizi sağlamıştır.

Bu görselleştirme, RMSE ve kayıp fonksiyonunun zaman içinde nasıl küçüldüğünü göstererek LSTM modelinin girdiyi ne kadar iyi özümlediğini izlememize olanak tanır. Çizim, modelin ideal bir çözüme doğru yakınsamasını sağlamaya yardımcı olur ve eğitim sürecine ilişkin faydalı bilgiler sunar. Eğitim seçeneklerinin dikkatli bir şekilde seçilmesi ve ayarlanması, LSTM ağının PV sistemi veri setinden öğrenmesine yardımcı olmak için kritik öneme sahiptir.

LSTM modeli, parametrelerini değiştirerek T ve G giriş varyasyonlarına yanıt olarak  $V_{mp}$ 'yi yüksek doğrulukla tahmin etme yeteneğini geliştirir. İyi tasarlanmış LSTM katmanları, istenen tahmin performansını elde etmek ve gelişmiş doğruluk ve genelleme yeteneklerine sahip oldukça etkili bir PV sistem modeli oluşturmak için optimize edilmiş eğitim seçenekleriyle birlikte çalışmalıdır.

#### 4.10.5. LSTM Ağının Eğitimi

LSTM model eğitimi, bir PV sistemi için hedef verileri ( $V_{mp}$ ) tahmin etmek veya izlemek için hazırlanan verileri kullanan en önemli adımlardan biridir. Bu çalışmada, LSTM ağının stack katmanının tasarımı, özellikle T ve G olmak üzere giriş kaynakları ile MPP'deki hedef çıkış voltajı arasındaki karmaşık bağlantıların anlaşılmasını sağlar. LSTM modeli, tahmin edilen  $V_{mp}$  değerleri ile normalleştirilmiş hedef değerler arasındaki farkı azaltmak için eğitim sırasında dahili parametrelerini tekrar tekrar değiştirir. LSTM ağı artık verilerdeki anlamlı örüntüleri ve bağımlılıkları yakalayabilir ve değişken çevresel koşulların varlığında doğru  $V_{mp}$  tahminlerine olanak tanır (Yu et al., 2021).

Eğitim sırasında LSTM ağı, tahmin edilen değerler ( $V_{mp}$ ) ile gerçek hedefler arasındaki farkı en aza indirmek için geri yayılım ve optimizasyon algoritmalarını kullanarak ağırlıklarını ve önyargılarını yinelemeli olarak ayarlar. Hata tatmin ediciyse, eğitim süreci başarılı kabul edilir. Aksi takdirde, LSTM modelinin hiper parametrelerinin ayarlanması

gerekir; bu da ağ yapısını değiştirerek veya alternatif optimizasyon tekniklerini keşfederek yapılabilir (Ergen & Kozat, 2018).

#### 4.11. LSTM Ağına Test Edilmesi

Bu adım, test veri kümesini (1 milyon veri kümesinin son %20'si) kullanarak eğitilmiş LSTM modelinin performansının değerlendirilmesini içerir. Test dizileri LSTM ağına girilir ve tahmin edilen  $V_{mp}$  değerleri gerçek hedeflerle karşılaştırılır. Performans, LSTM modelinin diğer MPPT kontrolörlerine (DNN, P&O) göre doğruluğunu ve güvenilirliğini değerlendirmek için ortalama karesel hata (MSE), kök ortalama karesel hata (RMSE) veya belirleme katsayısı (R-kare) gibi performans değerlendirme metrikleri kullanılarak hesaplanır.

##### 4.11.1. Eğitilmiş LSTM Ağına Değerlendirilmesi

Eğitim süreci tamamlandıktan sonra, LSTM modelinin performansı hem eğitim hem de test veri kümeleri kullanılarak değerlendirilir. Eğitilen LSTM ağı her iki veri kümesi için  $V_{mp}$  değerlerini tahmin ettiğinde, normalleştirilmiş tahminleri orijinal ölçeklerine döndürmek için denormalizasyon yöntemi kullanılır. Modelin hassasiyetini ve genelleştirilebilirliğini değerlendirmek için, tahmin edilen  $V_{mp}$  değerleri gerçek hedef değerlerle karşılaştırılır. Bu değerlendirme, model iyileştirme ve optimizasyon için potansiyel alanların belirlenmesine yardımcı olur ve modelin gerçek dünya koşulları altındaki tahmin gücü hakkında fikir verir.

##### 4.11.2. Eğitim ve Test Hatalarının Görselleştirilmesi

Bu adım, eğitim ve test verileri için gerçek hedef değerleri istenen hedef  $V_{mp}$  değerleriyle karşılaştıran görseller sağlar, böylece LSTM modelinin performansının tam bir resmini verir. Simüle edilen ve gerçek  $V_{mp}$  değerleri arasındaki farkları daha da vurgulamak için eğitim hatası ve test hatası grafikleri oluşturulur. Modelin doğruluğu ve etkinliği, eğitilmiş modeldeki kalıpları ve aykırı değerlerin varlığını belirlemeye yardımcı olabilecek görsel temsiller yardımıyla daha iyi değerlendirilebilir.

#### 4.12. Performans Değerlendirme Metriklerinin Seçimi

Dinamik sistemleri modellemek ve analiz etmek için grafiksel bir programlama ortamı olan Simulink - MATLAB, eğitilmiş LSTM modelini içe aktarmak için kullanılır. Sonuç olarak, LSTM modeli analiz edilmiş ve 100 kW şebekeye bağlı PV'nin Simulink modeli ile entegre edilmiştir. MSE, RMSE, MAE, R2 ve doğrulama kaybı gibi en önemli performans endeksleri, yazarlar tarafından (Chollet, n.d.)'de önerildiği gibi LSTM ağının performansını ölçmek için kullanılır. Zaman serisi tahmin uygulamaları bağlamında, bir LSTM ağının performans değerlendirmesi, modelin doğruluğunu ve etkinliğini değerlendirmek için çok önemlidir. Burada, zaman serisi tahmini için bir LSTM ağının performansının değerlendirilmesinde yer alan farklı adımların bir dökümü yer almaktadır. LSTM ağının performansı MSE, RMSE, MAE ve doğrulama kaybı gibi performans endekslerine göre test edilir.

##### 4.12.1. Ortalama Kare Hata (MSE)

Zaman serisi projeksiyonlarında regresyon modellerinin performansını değerlendirmek için MSE önemli bir metriktir. Zaman serileri boyunca beklenen değerler ile gerçek değerler arasındaki kare farklarındaki ortalama değişimin bir ölçüsüdür. MSE, hataları bir arada gruplandırarak daha büyük hataları RMSE'den daha ağır bir şekilde cezalandırır. Ancak RMSE'den farklı olarak MSE karekök almaz, bu da verilerin orijinal biriminde olmadığı anlamına gelir. RMSE'de olduğu gibi, düşük MSE değerleri gelişmiş model performansına işaret eder. RMSE'nin matematiksel gösterimi denklem (4.14)'te belirtilmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^n (V_{mp} - \hat{V}_{mp})^2 \quad (4.14)$$

Bu çalışmada, beklenen  $V_{mp}$  değerleri ile gerçek hedef değerler arasındaki sapmaların karelerinin ortalaması MSE ile hesaplanmıştır. Daha iyi tahmin doğruluğu daha düşük bir MSE ile gösterilir. Araştırmada düşük bir MSE, LSTM modelinin tahminlerinin gerçek  $V_{mp}$  değerlerinden çok az farklı olduğunu ve modelin sağlanan girdilere dayalı olarak  $V_{mp}$ 'yi tahmin etmedeki başarısını gösterir.



#### 4.12.2. Kök Ortalama Kare Hata (RMSE)

RMSE, zaman serisi tahminlerinin ve regresyonlarının doğruluğu için yaygın olarak kullanılan bir tahmin göstergesidir (Haifa Zahrah et al., 2021; Novitasari et al., 2020). Bir zaman serisinde tahmin edilen ve gerçek değerler arasındaki farkın ortalama karekökü ölçülür. Tahminler ile gerçeklik arasındaki hataların büyüklüğünü ölçer. RMSE'nin büyük hatalara karşı hassasiyeti vardır ve daha düşük RMSE, gelişmiş model performansını gösteren daha düşük hata anlamına gelir. MSE'nin matematiksel gösterimi denklem (4.15)'te verilmiştir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (V_{mp} - \hat{V}_{mp})^2} \quad (4.15)$$

Sıcaklık ve ışıınım girdilerine dayalı doğru bir  $V_{mp}$  tahmini, daha yüksek performans anlamına gelen düşük RMSE değerleri ile gösterilmektedir. Modelin tahminleri, daha düşük RMSE değerlerine sahip olduklarında gerçek  $V_{mp}$  değerlerine yakındır.

#### 4.12.3. Ortalama Mutlak Hata (MAE)

Zaman serisi tahminlerinde regresyon modellerinin analizinde MAE yaygın olarak uygulanan bir diğer metriktir. Tahmin değerleri ile gerçek değerler arasındaki mutlak farkların ortalaması olarak hesaplanır. MAE, RMSE gibi hataları ölçmez, böylece aykırı değerlerin hassasiyetini azaltır. Hataların yönünü dikkate almaz ve büyüklüklerinin bir ölçüsünü kullanır. Daha düşük MAE değerleri, söz konusu modelin daha yüksek performansını temsil eder. Matematiksel olarak MAE denklem (4.16)'da verilmiştir.

$$MAE = \frac{1}{N} \sum_{i=1}^n |V_{mp} - \hat{V}_{mp}| \quad (4.16)$$

MAE, ulaşılan hedef değerler ile tahmin edilen  $V_{mp}$  değerleri arasındaki mutlak tutarsızlıkların ortalamasını ifade eder. RMSE gibi, düşük MAE değerleri daha yüksek tahmin doğruluğu gösterir. MAE, RMSE'ye göre aykırı değerlere daha az duyarlı olduğundan model değerlendirmesi için güvenilir bir istatistiktir. Çalışma bağlamında, düşük bir MAE değeri, modelin LSTM tahminlerinin gerçek  $V_{mp}$  değerlerini tahmin etmede tipik olarak oldukça doğru olduğunu göstermektedir.

#### 4.12.4. R-kare (R2) veya Belirleme Katsayısı

R2 Regresyon, hedef değişkenindeki ( $V_{mp}$ ) varyasyonun ne kadarının LSTM modeli tarafından açıklanabileceğinin bir ölçüsüdür. Ölçek 0 ile 1 arasında değişir; burada 1, modelin varyasyonu tamamen açıkladığı ve 0, yatay bir çizgi olarak düşük performans gösterdiği anlamına gelir. Girdiler (T ve G) ile hedef çıktı  $V_{mp}$  arasındaki ilişki LSTM modeli tarafından tam olarak yakalanabildiği için daha büyük bir R2 değeri tercih edilir (Chicco et al., 2021). Araştırma bağlamında, yüksek bir R2 değeri modelin tahmin gücünü teyit eder ve mevcut çevresel parametrelere dayalı olarak  $V_{mp}$ 'yi başarılı bir şekilde tahmin etme yeteneğini gösterir.

#### 4.12.5. Doğrulama Kaybı

LSTM ağının eğitim sürecinde, eğitim için kullanılan veri kümesi test veri kümesinden farklıdır. Burada doğrulama kaybı, MSE veya MAE gibi belirli bir hata fonksiyonu kullanılarak, beklenen değerler doğrulama veri kümesindeki gerçek değerlerle karşılaştırılarak hesaplanır (Chicco et al., 2021). Kayıp fonksiyonu, modellerin yeni, görülmemiş verileri ne kadar iyi genelleştirebileceğini dikkate alır. Model, doğrulama kaybını azaltmak amacıyla eğitim süreci sırasında dahili parametrelerini değiştirmek için bir optimizasyon yaklaşımı (stokastik gradyan inişi gibi) kullanır. Modelin daha iyi genelleme performansı, daha küçük bir doğrulama kaybı ile gösterilir. Doğrulama kaybı için matematiksel denklem, denklem (4.17)'de verilmiştir.

$$\text{Doğrulama Kaybı} = \frac{1}{2} \left( \frac{1}{N} \sum_{i=1}^n (V_{mp} - \hat{V}_{mp}) \right) \quad (4.17)$$

Denklem (4.14) ile (4.17)'de modellenen tüm performans endeks parametrelerinin matematiksel formu, ML ve DL algoritmalarının performansını değerlendirmek için temel ve yaygın olarak kullanılan değerlendirme ölçütleridir (Forootan et al., 2022). (4.7) ile (4.10) arasındaki denklemlerde, N 1.000.000 net veri örneğini,  $V_{mp}$  gerçek çıktıyı veya hedef değeri ve  $\hat{V}_{mp}$  LSTM modelinden tahmin edilen veya izlenen çıktıyı veya hedef değeri temsil eder. MATLAB'de bir LSTM ağının performansını değerlendirmek için model eğitilmeli ve doğrulanmalı, ölçümler hesaplanmalı ve model daha sonra sonuçlara göre ayarlanmalıdır. RMSE ve MAE, tahmin doğruluğunu ölçmek için

kullanımı kolay ve yaygın olarak kullanılan göstergelerdir. Geri çağırma ve F1 puanı, LSTM hassasiyeti ile zaman serisi tahmini için uygun değildir.

#### 4.13. Şebekeye Bağlı PV Sistem İçin Üç Fazlı İnverter


Üç fazlı PV inverter, güneş panellerinden gelen Doğru Akımı (DC) şebeke ile senkronize alternatif akıma dönüştürdüğü için bir PV dizisini şebekeye entegre etmek için gereken çok önemli bir bileşendir. Altı anahtarlı basit iki aşamalı inverterler bu dönüşümü gerçekleştirebilir, ancak artan harmonikler, voltaj adımları ve daha düşük verimlilik gibi dezavantajları vardır. Faz başına ikiden fazla gerilim seviyesine sahip çok seviyeli inverterler (MLI) şebeke entegrasyonu için daha iyi dalga şekilleri sağlayabilir. İnverterlerdeki daha fazla artış harmonikleri azaltır ancak anahtarlama kaybını da artırır (Karaca & Bektas, 2016); (Zeb et al., 2018). Bu tezde, DC bağlantı kapasitörleri, anahtarlar ve diyotların kombinasyonunu kullanan popüler bir üç fazlı MLI, yani NPC voltaj kaynaklı inverter incelenmiştir. NPC inverter, geleneksel iki seviyeli inverterlere göre daha düşük harmonik bozulma, daha düşük gerilim dalgalanması, daha yüksek verimlilik ve daha az gürültü avantajlarına sahiptir. Bu özellikler NPC inverterleri yenilenebilir enerji kaynaklarının şebekeye entegrasyonu için ideal bir çözüm haline getirmektedir.

##### 4.13.1. NPC İnvörtöre Genel Bakış

NPC inverterler, faz başına üç veya daha fazla çıkış gerilimi seviyesi sağlamak için giriş tarafı kapasitörleri ile DC barasının merkezi noktasını alır. İki seviyeli bir inverterle karşılaştırıldığında, NPC'nin çok katmanlı yapısı, üç seviyeli bir dalga formu oluşturarak daha küçük voltaj adımlarına ve harmoniklere izin verir. Daha küçük gerilim adımları ve çok katmanlı dalga biçimleri düşük dereceli harmoniklerin ve  $dv/dt$  geriliminin azaltılmasına yardımcı olur (Bektas & Karaca, 2019). NPC inverterler bu avantajı modüle edilmiş tamamlayıcı çift anahtarlama ve nötr nokta erişimi ile elde eder. Olağanüstü harmonik özellikleri nedeniyle NPC inverterler, sinüzoidal PWM kullanan üç fazlı şebekeye bağlı PV sistemleri için özellikle uygundur. NPC inverterler, düşük bozulma ile yüksek kaliteli sinyaller üretebildikleri için şebeke gereksinimlerini karşılar.

#### 4.13.2. NPC İnvörtör Tasarımı

Üç fazlı bir NPC inverter sistemi, her biri A, B ve C Fazları olarak etiketlenmiş farklı fazları temsil eden üç ayrı dal veya bacadan oluşur. Şekil 4.6'da gösterildiği gibi faz bacağı, tüm fazlar için toplam 12 anahtar ve 12 diyot olmak üzere dört anahtar ve dört diyot içerir.



Şekil 4.6. Üç fazlı NPC gerilim kaynaklı dönüştürücünün şematik diyagramı

Kontrollü güç akışı, bağlı fazın her bir bacağında tamamlayıcı çiftler halinde çalışan anahtarlar tarafından üretilir. Faz A çalışması S1a, S2a, S3a ve S4a olarak adlandırılan dört anahtar tarafından kontrol edilir. Benzer şekilde, Faz B bacağında üst tamamlayıcı anahtarlar S1b ve S2b ve alt tamamlayıcı anahtarlar S3b ve S4b bulunur. Aynı şekilde, Faz C bacağında üst tamamlayıcı anahtar çifti S1c ve S2c ve alt tamamlayıcı anahtar çifti S3c ve S4c bulunur.

Bu yapılandırma, her bir faz terminali ile DC kaynağı arasında akan akımın hassas bir şekilde kontrol edilmesini sağlar. A fazı için NPC invertörünün çıkışındaki üç voltaj seviyesine ( $+V_{dc}/2$ , 0,  $-V_{dc}/2$ ) erişim mekanizması aşağıda açıklanmıştır. Benzer bir süreç diğer iki faz (B ve C) için de geçerlidir.

#### 4.13.3. NPC İnvörtörün Çalışması

NPC inverterin çalışması, 3 fazlı bir güç sisteminde çok seviyeli çıkış gerilimlerinin üretimi üzerinde hassas kontrol sağlayan sofistike bir anahtar ve diyot konfigürasyonu gerektirir. NPC invertör, geleneksel 2 seviyeli invertöre kıyasla daha az harmonik içeriğe sahip 3 seviyeli bir çıkış sağlar. İstenen 3 seviyeli gerilimleri elde etme mekanizması ( $+V_{dc}/2$ , 0,  $-V_{dc}/2$ ) (Abdelsalam et al., 2021; YOUNAS et al., 2019).

Üç fazlı bir NPC invertör, her biri A, B ve C Fazları olarak etiketlenmiş farklı fazları temsil eden üç ayrı dal veya bacadan oluşur. Her faz bacağı, tüm fazlar için toplam 12 anahtar ve 12 diyot için dört anahtar ve dört diyot içerir. Kontrollü güç akışı, bağlı fazın her bir bacağında tamamlayıcı çiftler halinde çalışan anahtarlar tarafından üretilir. Faz A çalışması S1a, S2a, S3a ve S4a olarak adlandırılan dört anahtar tarafından kontrol edilir. Benzer şekilde, Faz B bacağında üst tamamlayıcı anahtarlar S1b ve S2b ve alt tamamlayıcı anahtarlar S3b ve S4b bulunur. Benzer şekilde, Faz C bacağında üst tamamlayıcı anahtar çiftleri S1c ve S2c ve alt tamamlayıcı anahtar çiftleri S3c ve S4c bulunur.

NPC inverter, her faz için üç çıkış voltaj seviyesi üretmek üzere toplam 12 aktif anahtar (faz ayağı başına 4) ve 12 sıkıştırma diyotu (faz ayağı başına 4) kullanır. Her faz bacağı 2 tamamlayıcı anahtar çifti içerir- bir üst çift (S1, S2) ve bir alt çift (S3, S4). Serbest dönüş diyodu (D1, D2, D3, D4), S1 veya S2 açıkken D1 ve D2 çıkışı pozitif DC barasına sıkıştırarak, S3 veya S4 açıkken D3 ve D4 negatif DC bara rayına sıkıştırarak şekilde düzenlenmiştir.  $V_{dc}/2$  çıkışı için S1 ve S2 açılır ve faz çıkışı D1 ve D2'nin orta noktasına kelepçelenir. 0V çıkış için S1 ve S3 veya S2 ve S4 açılır ve çıkış sırasıyla D2 ve D3 veya D1 ve D4 üzerinden DC barasının orta noktasına kelepçelenir.

Aynı şekilde- $V_{dc}/2$  çıkışı için S3 ve S4 açılır ve faz D3 ve D4 üzerinden negatif DC rayına bağlanır. Yedeklilik ek esneklik ve hata toleransı sağlar. Anahtarlama durumları ile çalışma prensibi **Çizelge 4.3**'te listelenmiştir.

**Çizelge 4.3.** NPC inverterin her fazındaki anahtarlama durumları ve karşılık gelen çıkış gerilimi

| Faz      | S1  | S2  | S3  | S4  | Çıkış Gerilimi      |
|----------|-----|-----|-----|-----|---------------------|
| <b>A</b> | ON  | ON  | OFF | OFF | +V <sub>dc</sub> /2 |
|          | OFF | ON  | ON  | OFF | 0V                  |
|          | OFF | OFF | ON  | ON  | -V <sub>dc</sub> /2 |
| <b>B</b> | ON  | ON  | OFF | OFF | +V <sub>dc</sub> /2 |
|          | OFF | ON  | ON  | OFF | 0V                  |
|          | OFF | OFF | ON  | ON  | -V <sub>dc</sub> /2 |
| <b>C</b> | ON  | ON  | OFF | OFF | +V <sub>dc</sub> /2 |
|          | OFF | ON  | ON  | OFF | 0V                  |
|          | OFF | OFF | ON  | ON  | -V <sub>dc</sub> /2 |

Üç seviyeli nötr nokta kenetli (NPC) inverter, DC güneş enerjisini verimli bir şekilde AC şebeke uyumlu güce dönüştüren şebekeye bağlı solar PV sistemlerinin ayrılmaz bir parçasıdır. Geleneksel iki seviyeli invertörlerle karşılaştırıldığında, daha geniş bir çıkış voltajı aralığına sahip üç seviyeli NPC invertörler üstün performans gösterir ve harmonikleri en aza indirir. Çıkış dalga biçiminin kalitesini artırmak için hat gerilimi modülasyonu, darbe genişlik modülasyonu (PWM) teknikleri ve alçak geçiren LC filtreleri (LCL) kullanılır.

Bölüm 3'te tartışıldığı gibi, sinüzoidal PWM dalga biçimi verimliliği artırır ve anahtarlama kayıplarını azaltır. LCL filtresi ile elde edilen harmonik azaltma ve sistem stabilizasyonu işlevi de **Bölüm 3'te** ayrıntılı olarak açıklanmaktadır. Entegre NPC invertör, PWM ve LCL filtreleme içeren bu karmaşık sistem, gelecekte sürdürülebilir enerji gelişimi için verimli ve harmoniksiz güç dönüşümü ve şebeke entegrasyonu sağlayacak şebeke bağlantılı solar PV sistemlerindeki ilerlemeleri göstermektedir.

#### 4.14. Bölüm Özeti

Önerilen bu araştırma metodolojisi bölümü genel bir bakış, mimari, hiperparametreler ve çeşitli LSTM türlerinin açıklamalarını içermektedir. Çeşitli LSTM ağları arasında önerilen stack LSTM'nin seçimi, kapsamı ve avantajları vurgulanmaktadır. Önerilen stack LSTM hem geleneksel hem de son teknoloji ürünü akıllı MPPT kontrolörleri ile karşılaştırıldıktan sonra, önerilen LSTM'nin uygulanabilirliği doğrulanmıştır. Stack LSTM'yi önerilen PV sisteminde bir MPPT denetleyicisi olarak uygulamadan önce, önerilen PV sisteminin kısa bir açıklaması, PV dizisinin özellikleri ve MPPT denetleyicisinin çalışması vurgulanmakta, ardından girişlerin (T, G) ve hedef ( $V_{mp}$ ) verilerinin oluşturulması gelmektedir. Eğitim seçenekleri seçildikten sonra, toplu LSTM modeli hiper parametrelerle optimize edilir ve üretilen veriler üzerinde eğitilir. Model daha sonra görünmeyen veriler kullanılarak test edilir ve önerilen modelin ne kadar iyi çalıştığını göstermek için değerlendirme kriterleri tanımlanır. Tüm açıklamanın sonuçları **5. bölümde** görselleştirilmekte ve tartışılmaktadır.

Bir sonraki bölümde, önerilen LSTM tabanlı MPPT kontrolörünün bulguları açıklanmakta ve son teknoloji algoritmaların bulguları ile karşılaştırılmakta ve ardından elde edilen maksimum güç verimli bir şekilde şebekeye aktarılmaktadır. Bu araştırma, yenilenebilir enerji kaynaklarının kullanımını en üst düzeye çıkarmak ve PV sistemin

genel performansını iyileştirmek için içgörülü farkındalık sağlayarak, solar PV sistemlerinde verimli güç üretimi için LSTM ağlarının potansiyelini vurgulamaktadır.



## 5. SONUÇLAR VE TARTIŞMA

Bu bölümde, şebekeye bağlı PV sistemleri için önerilen Uzun Kısa Süreli Bellek (LSTM) tabanlı maksimum güç noktası izleme (MPPT) kontrolörünün simülasyon sonuçları ve tartışması Simulink MATLAB 2023© Derin Ağ Tasarımcısı (DND) Araç Kutusu kullanılarak gerçekleştirilmiştir. SunPower fotovoltaiik (PV) modülü, MATLAB'daki simülasyonlar için dikkate alınmıştır. Bu sadece uygun maliyetli, güvenli ve yinelemeli bir yaklaşım sağlamakla kalmaz, aynı zamanda gerçek zamanlı endüstri ihtiyaçlarını büyük ölçüde karşılar ve karmaşık sistemleri anlamada ve yenilenebilir enerji alanındaki profesyonelleri eğitmede öneminin altını çizer. Kullanılan SunPower TS-SPR-315 PV modülü 100,2 kW güç sağlamaktadır ( $P_{mp} = P_{max} * N_p * N_s = 315 * 65 * 5 = 102 \text{ kW}$ ).

Önerilen model, ışınım (G) ve sıcaklık (T) olmak üzere iki girdiye (öngörücü) ve MPP'deki gerilim ( $V_{mp}$ ) olan tek bir hedef çıktıya dayanmaktadır. PV dizisinin hesaplanan gücü 100,2 kW olup, Standart Test Koşullarında (STC)  $G = 1000 \text{ W/m}^2$  ve  $T = 25 \text{ °C}$ 'de yaklaşık 100 kW gerçek güç vermektedir. Önerilen LSTM tabanlı MPPT kontrolörünün simülasyon sonuçları, geleneksel P&O MPPT ve Derin Öğrenme (DL) tabanlı DNN- MPPT kontrolörü ile karşılaştırılmış ve performans değerlendirme parametreleri kullanılarak önerilen LSTM'nin üstünlüğü sağlanmıştır. Simülasyon sürecinde, veri toplama, ön işleme ve bölme dahil olmak üzere Makine Öğrenimi (ML) ve DL algoritmalarının eğitilmesi ve test edilmesi için gerekli tüm adımlar MATLAB M-File kodlaması kullanılarak gerçekleştirilmiştir. Ardından, eğitilen MPPT modelleri, şebekeye bağlı PV modeline entegre edilmek üzere Simulink'e aktarılır. Daha sonra, MPPT kontrolörlerinin verimliliğini, DC bağlantı voltaj regülasyonunu ve şebekeye güç aktarımını değerlendirmek için eğitilmiş MPPT modellerine yeni görünmeyen giriş sinyalleri (G, T) verilir. Bölümün geri kalanı aşağıdaki gibi düzenlenmiştir:

- Veri Toplama, Ön İşleme ve Görselleştirme
- Model Eğitimi ve Testi
- Eğitilmiş Modelin Simulink'e Aktarımı ve Şebekeye Bağlı PV'ye Entegre Edilmesi
- İlk Aşamada MPPT Kontrolör Performansı
- İnvertör Kontrolü ve PV'den Şebekeye Güç Aktarımı



## 5.1. Veri Toplama

Denetimli ML ve DL ağlarında, girdi ve hedef veri setlerinin toplanması, ağın tasarlanması ve eğitilmesinden önceki en önemli adımdır. Bu tezde, toplanan veri seti hem girdiler (G, T) hem de tek bir hedef veya çıktı ( $V_{mp}$ ) için bir milyon veri noktası içermektedir. Giriş ve hedef veri setinin toplanması ve bölünmesi için ayrıntılı adımlar hem DNN hem de önerilen stack LSTM için geçerli olan aşağıdaki alt bölümlerde açıklanmaktadır.


### 5.1.1. Tam Girdi Veri Seti

Denetimli bir DL yöntemi olarak önerilen stack LSTM ağı, girdi ve hedef veriler arasındaki karmaşık ilişkileri anlamak için hem girdi hem de hedef verilere ihtiyaç duyar. Kullanılan veri seti, küçük, dağıtılmış 100 kW PV sistemlerinin karmaşıklığını ve kaynak kısıtlamalarını dengeleyen ve pratik kaynak kısıtlamaları dahilinde LSTM'nin performansını artıran bir milyon veri noktası içermektedir.  $W/m^2$  birimindeki güneş G verileri Ulusal Yenilenebilir Enerji Laboratuvarı (NREL), Avrupa Güneş Radyasyon Atlası (ESRA) ve Dünya Radyasyon Veri Merkezi (WRDC) gibi çeşitli saygın kaynaklardan temin edilebilir.

Bu kaynaklarda mevcut olan değerler PV tesisinin coğrafi konumuna göre değişir ancak bu değerler 0 ila 10 veya 20  $w/m^2$  gibi çok küçük aralıklardadır. Normalde, simülasyon 0 ile 1000  $w/m^2$  arasındaki G değerleri üzerinde gerçekleştirilir. Bu tezde, gerçek G değerleri ve etkileri analiz edilmiş ve daha sonra **Bölüm 4'te** açıklandığı gibi denklemler kullanılarak kendi verileri oluşturulmuştur.

Bu tezde, veri yapısı ve girdilerin davranışı ilk olarak yukarıdaki kaynaklardan doğrulanmış ve ardından MATLAB 2023© kullanılarak istenen aralıkta örnek bir veri kümesi oluşturulmuştur. Benzer veri oluşturma veya toplama yaklaşımları (R. B. Roy et al., 2021), ve (Srinivasan & Ramalingam Balamurugan, 2022)'de yazarlar tarafından benimsenmiştir. Girdileri ve hedef verileri içeren veri setinin tamamı **Şekil 5.1**'de gösterilmektedir. Bu tezde kullanılan iki giriş sinyali G ve T'dir; burada G 0- 1000  $w/m^2$  arasında ve T 20- 80°C arasında değişmektedir ve her ikisi de sırasıyla **(4.8) ve (4.9)** denklemlerinden elde edilmektedir. G ve T değerleri için benzer bir veri toplama yaklaşımı (R. B. Roy et al., 2021) tarafından da kullanılmıştır. Hedef çıkış, yazarların (Srinivasan & Ramalingam Balamurugan, 2022)'deki tavsiyelerini takiben denklem

(4.11) kullanılarak 255-275V arasında değişen  $V_{mp}$ 'dir. Giriş ve hedef veri denklemleri ve ayrıntılı açıklamalar **Bölüm 4'te** verilmiştir. Bu kapsamlı veri seti, önerilen stack LSTM modellerinin, girişlerin değerlerindeki değişikliklere rağmen doğru MPPT için doğrusal olmayan karmaşık giriş-hedef ilişkilerini ortaya çıkarmasını sağlar.




**Şekil 5.1.** Her biri 1 milyon veri noktası içeren tam girdi ve hedef veri seti

### 5.1.2. Eğitim Veri Seti

Veri setinin bir eğitim ve bir test grubuna doğru şekilde bölünmesi, denetimli DL modelleri için çok önemlidir. Bu tezde, (Gholamy et al., 2018)'de önerilen standart 80/20 veri bölme kuralı dikkate alınmıştır. 1 milyon örneğin ilk %80'i eğitim için, kalan %20'si ise modelin genellemesini test etmek için kullanılır. Eğitim ve test arasındaki bu kategorizasyon, aşırı öğrenmeyi önler ve gerçekçi bir performans tahmini sağlar. Eğitim veri kümesi, her biri sırasıyla 0-1000  $w/m^2$ , 20-80 $^{\circ}C$  ve 255-275V arasında değişen  $G$ ,  $T$  ve hedef  $V_{mp}$  değerleri için toplam veri kümesinin %80'i olan 800.000 örnek içerir ve bu değerler **Şekil 5.2'de** gösterildiği gibi LSTM ağlarının karmaşık giriş-çıkış ilişkilerini

öğrenmesi için çok önemlidir. Çok sayıda etiketli veri seti örneği, LSTM modelinin gerçek dünyadaki çalışma koşullarını optimum  $V_{mp}$  ile eşleştirmesini sağlar. Çok sayıda etiketli örnek, veri odaklı DL yaklaşımını destekleyerek LSTM modelinin geleneksel tekniklerle yakalanamayan MPPT kontrolörünü genelleştirmek için kısıtlı kalıpları tespit etmesini sağlar. Böylece, 800.000 farklı eğitim örneği, gerçek dünya uygulamalarında değişken PV sistemleri için sağlam MPPT performansı elde etmek için temel sağlar.




Şekil 5.2. Toplam veri örneklerinin ilk %80'ini içeren eğitim veri seti

### 5.1.3. Test Veri Seti

Toplam örneklerin %20'si olan 200.000 örnekten oluşan test veri seti, gerçek performansın dikkatli bir şekilde değerlendirilmesini sağlar. Sırasıyla 0-1000 w/m<sup>2</sup>, 20-80 °C ve 255-275V değerlerini içeren G, T ve Vmp'yi temsil eden test verileri, Şekil 5.3'te gösterildiği gibi görünmeyen veriler olarak kabul edilir. Bu kapsamlı test verisi, model doğruluk tahminlerinde yanlılığı önler. Büyük miktarda görünmeyen verinin değerlendirilmesi, eğitilmiş ML veya DL modelinin genelleştirilebilirliğini ölçer. Test

metrikleri, iyi eğitilmiş bir LSTM modelinin aşırı uyum olmadan gerçek dünya MPPT kontrolündeki etkinliğini göstermektedir. Esasen, tüm veri setinin %20'si olan 200.000 farklı test vakası, PV çalışma ortamında MPPT'nin etkinliğini gerçekten yansıtmaktadır (Alsharef et al., 2022). Test veri seti ve sonuçları, geleneksel tekniklere karşı kıyaslamanın ayrılmaz bir parçasıdır.



Şekil 5.3. Toplam veri örneklerinin son %20'sini içeren test veri seti


## 5.2. Veri Ön İşleme ve Normalleştirme

Verileri eğitim ve test veri setlerine ayırdıktan sonra, bir diğer önemli adım, toplu LSTM DL modelini eğitmek için uygun verileri temizlemek ve normalleştirmek için kullanılan "veri ön işlemedir". Bir DL modelini eğitmeden önce verilerin normalleştirilmesi çok önemlidir çünkü tüm özellikleri ortak bir ölçeğe dönüştürür ve istikrarlı bir yakınsama sağlar. Normalleştirme olmadan, farklı veri aralıkları modellemeyi bozabilir ve saptırabilir. İki yaygın yöntem, öz değerlerin 0-1 aralığında ölçeklendirildiği min-max normalizasyonu ve verilerin ortalama etrafında ortalanan

standart sapma ile ölçeklendirildiği z-skor normalizasyonudur (Bhanja & Das, 2018). Ortalama, veri kümesinin ortalama değerini temsil ederken, standart sapma, ortalama etrafındaki değerlerin dağılımını ölçerek verilerin dağılımı hakkında fikir verir. Ortalama ve standart sapma kullanılarak hesaplanan Z skorları aykırı değerlere karşı dayanıklıdır ve bu nedenle aşırı değerlerin ölçekleme yöntemini bozabileceği gerçek dünya veri kümelerinde özellikle değerlidir. Ayrıca normalleştirme, DL algoritmalarının her bir özelliğin katkılarını etkili bir şekilde öğrenmesi için ortak bir temel sağlar.

### 5.2.1. Eğitim Verilerinin Normalleştirilmesi

G, T ve  $V_{mp}$ 'nin ham eğitim veri seti değerleri, önceki alt bölümlerde açıklandığı gibi sırasıyla 0-1000, 20-80 ve 255-275 arasında değişmektedir. Ham verileri ortalaması 0 ve standart sapması -3 ile 3 olan normalleştirilmiş z-değerlerine dönüştüren Z-skor normalizasyonu uygulanmıştır. Bu çalışmadaki veriler -1,7 ile 1,7 arasında STD değerlerine sahiptir, bu da verilerin çoğunun ortalama değere yakın olduğunu ve aykırı değer olmadığını gösterir (Asesh, 2022). Tüm değişkenler için y ekseninde z değerleri -1,7 ile 1,7 arasında değişirken, x ekseninde sınırları (%80 örneklem) Şekil 5.4'te gösterildiği gibi değişmeden kalmıştır.




Şekil 5.4. Ham eğitim veri setine uygulanan Z-skor normalizasyonu

Normalizasyonun -1,7 ile 1,7 arasındaki tekdüze dağılım aralığı, farklı değişkenleri çarpıklık olmadan ortak bir ölçeğe getirmede başarılı olduğunu göstermektedir. Z-değeri normalizasyonu, sabit kesme değerleri yerine her bir değişkenin dağılımının istatistiklerine odaklanarak aykırı değerler için bile dengeli bir normalizasyon sağlar.

### 5.2.2. Test Verilerinin Normalizasyonu

Modelin genellenebilirliğini değerlendirmek için örneklerin son %20'si test veri seti olarak ayrılmıştır. Eğitim verilerinde olduğu gibi, test veri setinin girdi ve çıktı değişkenleri de z değeri normalleştirme yöntemi kullanılarak normalleştirilmiştir. Bu işlem, ham G, T ve  $V_{mp}$  test verilerini Şekil 5.5'te gösterildiği gibi -1,7 ile 1,7 arasında normalleştirilmiş bir aralığa dönüştürmüştür.



Şekil 5.5. Ham test veri setine uygulanan Z-skor normalizasyonu

Verilerin bölünmesine rağmen tutarlı normalize edilmiş aralıklar, test verilerinin dağılımının eğitim seti gibi olduğunu göstermektedir. Eğitim dağılımının yalnızca ortalamasını ve standart sapmasını kullanan normalizasyon, aynı istatistiksel dönüşümün test verilerine de uygulanmasını sağlar. Bu tutarlı normalizasyon, modelin aynı operasyonel dağılımdan yeni örneklerle genelleme yeteneğinin tarafsız bir değerlendirmesi için gereklidir. Normalize edilmiş alan, test verilerinin eğitim setinin özelliklerine göre etkili bir şekilde normalleştirildiğini doğrular.

Bu bölümde, bölünmüş eğitim ve test verileri, DL modellerinin eğitimi için çok önemli bir adım olan normalizasyona tabi tutulur. Normalizasyon hızlı yakınsama sağlar, doğru aktivasyon fonksiyonunun seçilmesine yardımcı olur ve aşırı uyumu önlerken model kararlılığını artırır. Normalleştirmeden sonra bölüm, eğitimden önce veri özelliklerini anlamak için veri görselleştirmeye doğru ilerlemektedir.


### 5.3. Veri Görselleştirme

Veri görselleştirme, 1 milyon örnekten oluşan örneklenmiş veri kümesinin tamamında veri toplama ve normalleştirmenin ardından gelen bir diğer hayati adımdır. Bu,  $G$  (0-1000) ve  $T$  (20-80) girdilerini hedef  $V_{mp}$  (255-275) çıktısına eşler. Bu önceden işlenmiş verilerin görselleştirilmesi, ham verilerde belirgin olmayan gizli kalıpları ve ilişkileri ortaya çıkarır. Kutu grafikleri, histogramlar ve korelasyon matrisleri gibi teknikler verilerdeki dağılımları, aykırı değerleri, korelasyonları ve doğrusal olmayan ilişkileri etkili bir şekilde görselleştirebilir.

Yüksek kaliteli görselleştirmeler uygun normalleştirmeyi sağlar, anomalileri yakalar, özelliklerin önemini vurgular ve sadece ham verilere bakarak kolayca gözden kaçabilecek içgörülerini ortaya çıkarır (Inglis et al., 2022). Bu nedenle, DL'de normalleştirilmiş verilerin görselleştirilmesi, model seçimi ve hiperparametrelerin veri özelliklerine göre ayarlanması için paha biçilmez bir rehberlik sağlar. Etkileşimli görsel analitik araçlar, özellik etkileşimlerini ölçmek için verileri birden fazla perspektiften dilimlemeye olanak tanır. Verilerin zamansal veya mekansal boyutlarda görselleştirilmesi, kaliteli temsiller sağlamak için zaman serileri ve mekansal modeller için de kritik öneme sahiptir. Genel olarak, çok yönlü görselleştirmeler yoluyla "verilerin görünürlüğü" üstün makine öğrenimi modellerini katalize eder.

### 5.3.1. Kutu Grafikleri ve Histogram Tabanlı Veri Görselleştirme

Kutu grafikleri ve histogramlar istatistiksel analizde önemli araçlardır; kutu grafikleri meydanları, çeyrekleri ve aykırı değerleri gösterirken, histogramlar verilerin frekans dağılımını gösterir (Aseş, 2022). Her ikisi de merkezi eğilimi, dağılımı, şekli ve aykırı değerlerin varlığını kısaca göstererek ham verilerin önemli yönlerini ortaya çıkarabilir. Bu grafiksel gösterimler yalnızca verilerin netliğini artırmakla kalmaz, aynı zamanda bilim ve araştırmada sağlam modelleme için paha biçilmez bir destek sağlar. **Şekil 5.6**, X ekseninin parametre değerlerini ( $G$ : 0-1000  $W/m^2$ ,  $T$ : 20-80  $^{\circ}C$  ve  $V_{mp}$ : 255-275 V) ve Y ekseninin frekansları temsil ettiği standartlaştırılmamış veri setinin nispeten tekdüze dağılımını göstermektedir. Bu tutarlılık, veri temsilde çeşitlilik sağlamak ve tahmin aralığını doğrulamaktadır. Veri setlerini temsil etmek için kutu grafikleri ve histogramların kullanılması, önemli kalıpları ve aykırı değerleri vurgularken veri setinin bütünlüğünü artırarak daha gerçekçi hale getirir.




**Şekil 5.6.** Normalleştirilmemiş verilerin kutu grafiği ve histogram tabanlı görselleştirilmesi

**Şekil 5.7** histogramı ve kutu grafiklerini tek tip bir ölçekte (-1,7 ila 1,7) ve z'ye normalize edilmiş olarak göstermektedir. Normalizasyon, farklı verilerin ortak bir ölçeğe normalize edilmesini sağlayarak karşılaştırmayı kolaylaştırır. Bu, veri tutarlılığı ve model esnekliği sağlar. Ayrıca histogram analizi, değiştirilmiş veri setinin davranışını anlamaya



yardımcı olur. -1,7 ila 1,7 aralığında, -1 veya 1'e yakın değerler ortalamaya yaklaşıldığını gösterirken, diğer değerler ortalamadan sapmayı gösterir. Dağılım modellerinin tam olarak bilinmesi, sonraki analizlerin güvenilirliğini artırır ve ön işleme aşamasının geçerliliğini teyit eder.



Şekil 5.7. Normalleştirilmiş verilerin kutu grafiği ve histogram tabanlı görselleştirilmesi

### 5.3.2. Korelasyon Tabanlı Veri Görselleştirme

Korelasyon matrisi, girdi değişkenleri ile hedef değişkenler arasındaki ilişkiyi anlamak için kullanışlı bir veri görselleştirme aracıdır (Haas et al., 2018). Isı haritaları, bir veri setindeki her bir değişken çifti arasındaki korelasyon katsayısını göstermek için kullanılır. Korelasyon katsayısı, iki değişken arasındaki doğrusal ilişkinin gücünü ve yönünü gösterir. Korelasyon katsayısının -1 olması mükemmel bir negatif korelasyonu, 1 olması mükemmel bir pozitif korelasyonu ve 0 olması ise korelasyon olmadığını gösterir. Önerilen girdi değişkenleri (G, T) ile hedef değişkenler arasındaki ilişki Şekil 5.8'de gösterildiği gibi bir korelasyon matrisi olarak temsil edilmekte ve noktalar aşağıda özetlenmektedir:


- İki girdi değişkeni (G, T) ve bir hedef (*Vmp*) kendi aralarında mükemmel bir korelasyona sahiptir ki bu doğrudur çünkü her değişken kendi içinde mükemmel bir korelasyona sahip olmalıdır.

- G ve T arasındaki 0,23 korelasyon değeri zayıf bir pozitif korelasyondur, yani G değeri arttıkça T değeri de bir miktar artacaktır. Bununla birlikte, ilişki çok güçlü değildir ve verilerde hala büyük bir dağılım vardır.
- T ve G arasında korelasyon yoktur (0.00), bu da iki değişken (T ve G) arasında bir ilişki olmadığını ve T değişkenindeki değişikliklerin G değişkeninin değerlerini etkilemediğini göstermektedir.
- G ve *Vmp* arasında güçlü bir pozitif korelasyon vardır (0.73). Bu, G değeri arttıkça *Vmp* değerinin de artma eğiliminde olduğu anlamına gelmektedir. İlişki güçlü ve pozitifdir ve verilerde nispeten az değişkenlik vardır.
- T ve *Vmp* değişkenleri -0,83 korelasyon değerine sahiptir ve bu da güçlü bir negatif ilişki sergilemektedir; yani T değeri arttıkça *Vmp* değeri azalacak ve bunun tersi de geçerli olacaktır. İlişki güçlüdür ve verilerde nispeten az dalgalanma vardır.

Yukarıdaki korelasyon analizi, verilerin doğru şekilde oluşturulmasını, normalleştirilmesini ve dağıtılmasını sağlayan PV dizisi yaklaşımımızı takip etmektedir. Solar PV'de G, *Vmp* ve PV gücünü doğrudan etkiler ve T, G ile *Vmp* arasında güçlü bir pozitif ilişki ve T ile *Vmp* arasında güçlü bir negatif ilişki ile yukarıdaki korelasyon analizinden de anlaşılacağı üzere *Vmp* ve PV gücü ile ters orantılıdır. **Şekil 5.8**'de gösterilen korelasyon sonuçlarından çıkan önemli bir sonuç, hem orijinal hem de normalleştirilmiş veriler için matris sonuçlarının benzerliğidir ve benzer durum yazarlar tarafından (Choi & Shin, 2021) 'de de önerilmektedir. G, T ve *Vmp* arasındaki korelasyonlar z-değeri normalizasyonundan etkilenmez, bu da göreceli ilişkilerin ve korelasyonların korunduğunu gösterir. Korelasyonların değişmeden kalması, normalleştirmenin doğru olduğunu ve ön işlemenin bütünlüğünün korunduğunu gösterir. Korunan korelasyon yapısı hem ham hem de normalleştirilmiş verileri kullanarak doğrudan karşılaştırma ve eğitime olanak tanır, böylece veri içeriğini değiştirmeden modelleme esnekliği sağlar.

Güçlü normalleştirme ve ayrıntılı görselleştirme dahil olmak üzere özenle seçilmiş 1 milyon örnek veri seti, kanıta dayalı DL'yi kolaylaştırır. Normalleştirme önemli ilişkilerden ödün vermeden tutarlılığı korurken, görselleştirme çok değişkenli korelasyonları ve varyansı ortaya çıkarır. Bu ön işleme, veri bütünlüğünü sağlar ve etkili

DL modellerini mümkün kılar. Doğru ön işleme esastır ve yapılandırılmış veri tabanları artık DNN ve LSTM DL model eğitimi için hazırdır.



Şekil 5.8. Normalleştirilmiş ve ham girdilerin (G, T) ve hedef (Vmp) verilerin korelasyon matrisi

#### 5.4. DL Tabanlı MPPT Modelinin Eğitimi


Başarılı veri toplama, normalleştirme ve görselleştirmeden sonra bu bölüm, bu araştırmanın temel alanı olan hem DNN hem de LSTM için geçerli olan DL modellerinin eğitimine doğru ilerlemektedir. Bu tezde, 100 kW'lık bir PV dizisini mikro şebekeye bağlamak için üç ana MPPT kontrolörü dikkate alınmıştır: (a) P&O MPPT kontrolörü, (b) DNN tabanlı MPPT kontrolörü ve önerilen stack LSTM tabanlı MPPT kontrolörü. P&O, ML veya DL tabanlı bir MPPT yöntemi değil, geleneksel bir yaklaşımdır ve eğitim veri setine ihtiyaç duymaz, bu nedenle P&O'nun kodu doğrudan MATLAB'da yazılır ve şebekeye bağlı PV modelinde kullanılmak üzere Simulink'e aktarılır. DNN ve LSTM dahil olmak üzere iki MPPT kontrolörünün geri kalanı, iki girişi (G, T) ve tek hedef çıkışı ( $V_{mp}$ ) 1 milyon veri noktasından oluşan önceden işlenmiş bir veri kümesi üzerinde eğitilmiştir. Bu DL modellerinin başarılı bir şekilde eğitilmesinden sonra, eğitim ve test hataları hesaplanmış ve her iki modelin performansı, performans değerlendirme parametreleri açısından karşılaştırılmıştır. Bu alt bölüm, ilk olarak DNN'nin eğitim sürecini ve ardından LSTM ağıнын eğitim ve test sürecini açıklayarak devam etmektedir.

### 5.4.1. DNN tabanlı MPP Ağ Eğitimi

İleri beslemeli çok katmanlı DNN'ler, karmaşık kalıpları ve doğrusal olmayan ilişkileri yakalamada yalnızca bir gizli katmana sahip geleneksel ANN'lardan daha iyi performans gösterir. Daha fazla katman ekleyerek, DNN'ler bilgiyi katmanlandırmak için soyut özellikler çıkarabilir ve hedef  $V_{mp}$  'yi tahmin etmek için değişkenlerdeki (örneğin, T ve G) karmaşık kalıpları yakalayabilir (Huo & Meckl, 2022). Bu nedenle, bu alt bölüm DNN ağının tasarımı ile devam etmekte, ardından etkili eğitim için hiperparametrelerin seçimi yapılmakta ve daha sonra görünmeyen veriler üzerinde test edilmektedir.

#### 5.4.1.1. DNN Mimarisi

Tek gizli katmanlı ANN, hedef değişken olarak  $V_{mp}$ 'yi ve T ve G değişkenlerimiz gibi belirli girdiler arasındaki doğrusal olmayan ilişkileri tahmin ederken nispeten daha basit veri modellerini modellemek için çok uygundur.



Şekil 5.9. 64 ve 32 birimlik iki gizli katmana sahip ileri beslemeli DNN mimarisi

Bununla birlikte, problem karmaşıklığı arttıkça, girdi verilerindeki kesinti ve hızlı değişikliklerle birlikte, ANN dizi tahmininde ağırlık optimizasyonunun üstesinden gelmek için birden fazla gizli katman gerektirir.

Buna karşılık, **Şekil 5.9**'da gösterildiği gibi sırasıyla 64 ve 32 birimlik iki gizli katmana sahip çok katmanlı ileri beslemeli DNN mimarisi, girdilerdeki (G, T) karmaşık örüntüleri yakalamada mükemmeldir. Bu çoklu katmanlar yalnızca regresyon görevlerini optimize etmekle kalmaz, aynı zamanda aşırı uyumu önleyerek hedef çıktımızı ( $V_{mp}$ ) tahmin etmek için çeşitli senaryolarda güçlü performans sağlar.

Z-skoru normalize edilmiş girdi veri seti (G ve T), sırasıyla 64 ve 32 nörondan oluşan katmanlar aracılığıyla işlemek için tanh aktivasyon fonksiyonunu kullanan DNN ağına aktarılmıştır. tanh, -1 ile 1 arasındaki kısıtlı aralıkta karmaşık doğrusal olmayan modelleri yakalayabildiği için seçilmiştir (Sharma et al., 2020). Bu karar, ağın tutarlılığını korurken ve gradyan kaybolma sorunlarından kaçınırken verilerdeki karmaşık ilişkileri temsil edebilmesini garanti eder. DNN'nin çıktısı, doğrusal bir fonksiyonla etkinleştirilen ve 255 ile 275 hedef aralığında tahminler üreten son çıktı katmanını tarafından problem alanının bağlamıyla uyumlu hale getirilir.

#### 5.4.1.2. DNN Hiperparametre Seçimi


Doğru hiperparametrelerin seçilmesi etkili eğitimin anahtarıdır. Bu tezde, eğitim ve test verileri için 80-20 bölme kuralı takip edilmiştir. Her iterasyondaki eğitim örneklerinin sayısını belirlemek için mini yığın boyutu 32 olarak seçilmiştir ve tüm eğitim veri kümesinin tam bir çalışmasını veya döngüsünü temsil eden toplam 50 epok dikkate alınmıştır. Epok sayısının daha da artırılması eğitim ilerlemesini iyileştirebilir, ancak aynı zamanda hesaplama süresini ve karmaşıklığını da artırır. Dikkatle seçilen 0,05 öğrenme oranı stabilizasyona, hızlı yakınsamaya ve parametre ayarının optimizasyonuna yardımcı olur (Liao et al., 2022). Ayrıca, L2 düzenlemesi (0.0001) aşırı ağırlık artışını önler ve Adam optimizasyon algoritması öğrenme sürecini hızlandırır. DNN'nin model mimarisi, hiperparametreleri ve performans değerlendirme parametreleri **Çizelge 5.1**'de listelenmiştir.

**Çizelge 5.1.** DNN ağıının ağ tasarımı, hiperparametreleri ve performans endeksleri


| Parametre                              | Değer                                  |
|----------------------------------------|----------------------------------------|
| <b>DNN Mimarisi Katman</b>             | İki Gizli Katman<br>(64 adet, 32 adet) |
| <b>Hiperparametreler</b>               |                                        |
| <b>Öğrenme Oranı</b>                   | 0.05                                   |
| <b>Bozunma Mekanizması</b>             | Uygulanan                              |
| <b>İklendirme</b>                      | Başlatma                               |
| <b>L2 Düzenlemesi</b>                  | 0.0001                                 |
| <b>Optimizasyon Algoritması</b>        | Âdem                                   |
| <b>Mini Grup Boyutu</b>                | 32                                     |
| <b>Eğitim-Doğrulama Ayrımı</b>         | 80-20                                  |
| <b>Performans Metrikleri</b>           |                                        |
| <b>Ortalama Kare Hatası (MSE)</b>      | 0.18561                                |
| <b>Kök Ortalama Kare Hatası (RMSE)</b> | 0.43083                                |
| <b>Ortalama Mutlak Hata (MAE)</b>      | 0.33843                                |
| <b>Kayıp Fonksiyonu Değeri</b>         | < 0.1                                  |
| <b>R-Kare (<math>R^2</math>)</b>       | 0.80438                                |

#### 5.4.1.3. DNN Eğitim İlerleme Durumu

Önceki aşamalarda 1 milyon kayıttan oluşan veriler toplanmış, normalize edilmiş ve görselleştirilmiştir. Veri kümesi %80 eğitim kümesi ve %20 test kümesi olarak ayrılmıştır. DNN ağı şimdi "train" fonksiyonu kullanılarak eğitim veri kümesi (Xtrain ve Ytrain) üzerinde eğitilmiştir. Model performansı ortalama karesel hata (MSE) ve kayıp fonksiyonu kullanılarak değerlendirilmiştir. **Şekil 5.10**'da gösterildiği gibi, 50 eğitim epokundan sonra MSE 0,18561'e düşmüş ve kayıp 0,1'in altına inmiştir. Bu azalmalar, gerçek hedef değerlerle hizalanmış giderek daha doğru tahminlere işaret etmektedir. Düşük nihai MSE ve kayıp değerleri, DNN modelinin yeni görülmeyen verilere etkili bir şekilde genelleme yapmasını sağlayan optimum eğitimi gösterir.



Şekil 5.10. FF DNN Ağının artan epoklarla eğitim ilerleme durumu



Şekil 5.11. (a) normalize edilmiş girdiler, (b) tahmin edilen değer ve (c) FF DNN kullanılarak gerçek ve tahmin edilen hedef Vmp arasındaki eğitim hatası

Normalize edilmiş eğitim girdileri (G, T), **Şekil 5.11(a)**'da gösterildiği gibi tasarlanan iki katmanlı DNN ağına beslenir ve ardından tahmin edilen çıktılar **Şekil 5.11 (b)**'de gösterildiği gibi eğitim hatasını hesaplamak için gerçek eğitim hedefleriyle karşılaştırılır. **Şekil 5.11 (c)**'de gösterilen eğitim hatası 0,45 gibi küçük bir aralıktadır, bu da hata büyüklüğünün küçük ve sıfıra yakın olduğunu gösterir, bu da gelecekte diğer bilinmeyen veri kümeleri üzerinde yapılacak testler için sağlamlık sağlar. Eğitim sürecinde 0,18'lik bir MSE değeri fark edilmesine rağmen, RMSE değeri neredeyse 0,45 olur, bu da tahmin edilen ve gerçek hedef değerler arasındaki fark hatası ile neredeyse aynıdır. DNN'lerin iyi eğitim performansı ve güvenilirliği göz önüne alındığında, bu sonuçlar aynı zamanda eğitilmiş DNN'lerin şebekeye bağlı PV sistemlerinin MPPT'si için uygun bir yaklaşım olarak kullanılmasını desteklemektedir.

#### 5.4.1.4. DNN Ağına Test Edilmesi


Eğitilen DNN modeli daha sonra görünmeyen verilerin kalan %20'si üzerinde test edilir. Test girişleri (G, T) **Şekil 5.12 (a)**'da gösterildiği gibi eğitilmiş DNN'ye verilir ve bu görünmeyen test edilmiş veriler üzerinde tahmin edilen çıktı elde edilir, ardından bu tahmin edilen çıktı **Şekil 5.12 (b)**'de gösterildiği gibi gerçek test hedefiyle karşılaştırılır. Sonuçlar, **Şekil 5.12 (c)**'de gösterildiği gibi, eğitim durumunda gözlemlendiği gibi sürekli olarak 0,45 hata aralığında kalmıştır. Yaklaşık 0,45 olan düşük hatalar da modelin geçerliliğini teyit etmekte ve gerçek dünyadaki güvenilirliğini ve PV sistemlerinin enerji üretimini yüksek doğrulukla optimize etme potansiyelini sağlamaktadır.

Başlangıçta, DNN modeli verilerin %80'i üzerinde eğitilir ve eğitim hatası gerçek hedef ile tahmin edilen hedef arasındaki fark alınarak hesaplanır. Daha sonra, DNN modeli verilerin görülmeyen %20'si üzerinde test edilir ve hata hesaplaması için benzer bir yaklaşım kullanılır. Eğitilen DNN modellerinin performansı yaygın kullanılan performans matrisleri kullanılarak değerlendirilir.

Performans parametrelerinin değerleri **Çizelge 5.1**'de listelenmiştir; Kök Ortalama Kare Hatası (RMSE) 0,43083'tür ve tahmin hatalarının ortalamasını ölçer. Ortalama Kare Hata (MSE) 0.18561'dir ve tahmin edilen değer ile gerçek hedef değer arasındaki ortalama kare sapmayı temsil eder. Ortalama Mutlak Hata (MAE) 0,33843'tür ve tahmin edilen değer ile hedef değer arasındaki ortalama mutlak farktır. Kayıp fonksiyonunun 0,1'den küçük değerleri, model parametrelerini optimize etmek için kullanılan tahmin edilen ve gerçek sonuçlar arasındaki farkı yansıtır. Son olarak,



0,9134'lük R-kare ( $R^2$ ), modelin girdilerden gelen hedefteki varyans oranını tahmin edebildiğini göstermektedir. Birlikte ele alındığında, bu ölçütler DNN modelinin değişken ışıınım ve sıcaklık girdilerine dayalı olarak bir PV sisteminin  $V_{mp}$  hedef değerini sağlam bir şekilde uydurabildiğini ve doğru bir şekilde tahmin edebildiğini göstermektedir. Düşük hata ve yüksek  $R^2$ , bu zaman serisi tahmin görevinde modelin iyi uygunluğunun ve güvenilirliğinin altını çizmektedir.



Şekil 5.12. (a) Test girdileri, (b) tahmin edilen test ve (c) FF DNN kullanılarak gerçek ve tahmin edilen hedef  $V_{mp}$  arasındaki test hatası


#### 5.4.2. LSTM tabanlı MPP Ağ Eğitimi

LSTM, benzersiz geçitli hücre yapısı sayesinde özellikle zaman serisi regresyon görevinde ( $G$ ,  $T$  girdileri ve hedef  $V_{mp}$ ) etkili performans sunar. Bu kapılı yapı, uzun vadeli bağımlılıkları korur ve uzun bir süre boyunca veri değişkenleri arasındaki örüntüleri tespit eder. DNN'lerin aksine, LSTM gradyan kaybını önler ve geçmişten gelen ilgili bilgilerin korunmasını sağlar. Bu dahili hafıza özelliği, hava durumu parametrelerinin eğilimlerini optimum güneş paneli konfigürasyonlarına eşlemek gibi görevler için kritik öneme sahiptir (Ozdemir et al., 2022). Ayrıca, LSTM sürekli verileri

işlemek için özel eğitim yöntemleri kullanır ve bu da DNN'lere göre üstün performansını büyük ölçüde artırır.

#### 5.4.2.1. LSTM Mimarisi


Solar PV dizisinde MPP çıkarımı için önerilen 100 kW PV şebekeye bağlı sistemimizin LSTM yapısı (zaman serisi regresyon görevi) Şekil 5.13'te gösterildiği gibi bir giriş katmanı, iki LSTM katmanı, iki bırakma katmanı, bir çıkış katmanı ve bir regresyon çıkış katmanından oluşmaktadır.



Şekil 5.13. MATLAB'ın Derin Ağ Tasarımcısı Araç Kutusunda LSTM katmanlarının gösterimi

Önerilen LSTM ağında, z-skor normalize edilmiş girdilere (0 ile 1000 arasında G değerleri ve 20 ile 80 arasında T değerleri) dayalı olarak, önerilen model 250 ile 280 arasında  $V_{mp}$  değerlerini tahmin etmektedir. Bu girdilere ve hedef çıktıya dayalı olarak, bilgi sırayla girdilerden birinci LSTM katmanına, ardından ikinci LSTM katmanına, daha sonra tam bağlantılı katmana ve son olarak istenen tahmini çıktıyla regresyon katmanına akar. İlk LSTM katmanı 64 gizli birimden ve -1 ile 1 arasındaki değerleri bastırarak zamansal örüntüleri yakalamak için tanh aktivasyonundan oluşur. Bunu, genelleştirmeyi kolaylaştırmak için bir bırakma katmanı (birimlerin %20'si devre dışı bırakılır) izler. Her LSTM katmanını, eğitim sırasında sinir bağlantılarının %20'sini rastgele devre dışı bırakarak aşırı uyumu önlemek için 0,2'lik bir bırakma katmanı takip eder. İkinci LSTM

katmanı, aynı aralığı koruyarak örüntüyü iyileştiren 32 birimden oluşur. İkinci LSTM katmanından sonra, başka bir bırakma katmanı kullanılır. Ardından, çıkış katmanına ulaşmadan önce, sağlamlığı artırmak için bir regresyon katmanı kullanılır. Önerilen LSTM mimarisindeki regresyon katmanı, ardışık Vmp değerlerini tahmin ederek 255 ile 275 arasındaki belirli bir hedef aralığını doğru bir şekilde eşler. LSTM ağının katman yapısı veya düzenlemesi Şekil 5.14'te gösterilmektedir. Çıkış katmanı, giriş hava koşulları (G, T) ile istenen çıkış voltajı (Vmp) arasındaki ince zamansal korelasyonu yakalamak için dikkatlice kalibre edilmiştir.



Şekil 5.14. Derin Ağ Tasarımcısında LSTM katmanlarının sırası

#### 5.4.2.2. LSTM Hiperparametre Seçimi

LSTM modeli, aynı karmaşıklığa sahip iki DL modelinin (DNN, LSTM) doğru bir şekilde karşılaştırılmasını sağlamak için DNN ağının hiper parametrelerine uyacak

şekilde optimize edilmiştir. Sabit bir 0,05 öğrenme oranı yakınsamayı sağlar ve uyarlanabilir bir Adam optimize edici öğrenme oranını dinamik olarak değiştirir. Aşırı uyumu önlemek için aynı eğitim/doğrulama oranı olan 80/20 kullanılmıştır. Verimliliği ve genellemeyi dengelemek için stack boyutu 32 olarak ayarlanmıştır. Model 50 epok ile eğitilmiştir; daha fazla epok RMSE'yi daha da azaltmış ancak hesaplama süresini artırmıştır. 0,05'lik bir öğrenme oranı, yetersiz uyum olmadan makul bir yakınsama oranı sağlamıştır. Uyarlanabilir Adam optimize edici, kararlılığı artırmak için eğitim sırasında öğrenme oranını dinamik olarak ayarlar. Hiperparametreler, doğruluğu en üst düzeye çıkarmak için girdi verilerine (G, T) dayalı olarak hassas şekilde ayarlanmıştır. **Çizelge 5.2**, ağ tasarımı, hiperparametreler ve LSTM ağı aracılığıyla elde edilen performans değerlendirme parametreleri sonuçlarının seçimini özetlemektedir.


**Çizelge 5.2.** LSTM ağının ağ tasarımı, hiperparametreleri ve performans endeksleri

| Parametre                       | Değer              |
|---------------------------------|--------------------|
| LSTM Mimarisi                   | İki Gizli Katman   |
| Katman                          | (64 adet, 32 adet) |
| <b>Hiperparametreler</b>        |                    |
| Öğrenme Oranı                   | 0.05               |
| Bozunma Mekanizması             | Uygulanan          |
| İklendirme                      | Başlatma           |
| L2 Düzenlemesi                  | 0.0001             |
| Optimizasyon Algoritması        | Âdem               |
| Mini Grup Boyutu                | 32                 |
| Eğitim-Doğrulama Ayrımı         | 80-20              |
| <b>Performans Metrikleri</b>    |                    |
| Ortalama Kare Hatası (MSE)      | 0.0023295          |
| Kök Ortalama Kare Hatası (RMSE) | 0.048265           |
| Ortalama Mutlak Hata (MAE)      | 0.033978           |
| Kayıp Fonksiyonu Değeri         | < 0.05             |
| R-Kare ( $R^2$ )                | 0.99768            |

Bu parametreler, optimum  $V_{mp}$  tahmini için G ve T modellerinin çoğaltılmasını sağlar. Performans değerlendirme sonuçları, zaman serisi verilerinin tahmini ve öngörüsü için tanınan LSTM'nin, şebekeye bağlı PV sistemleri için MPPT izleme veya çıkarma için çok uygun olduğunu göstermektedir. Simulink MATLAB Derin Ağ Tasarımcısı araç kutusu hiper-parametrelerin seçimini ve değiştirilmesini kolaylaştırmaktadır.

#### 5.4.2.3. LSTM Eğitimi İlerleme Durumu


Eğitim sürecinde, LSTM ağı RMSE açısından tutarlı bir iyileşme gösterirken, DNN yöntemi varsayılan olarak MSE açısından iyileşmeler göstermektedir. **Şekil 5.15**'te gösterildiği gibi LSTM'nin eğitim süreci, 50 eğitim epoku boyunca RMSE'yi kademeli olarak azaltmakta ve son epoka kadar 0,048265 gibi dikkate değer bir RMSE düşüklüğüne ulaşarak DNN'nin 0,43083'lük RMSE'sini geride bırakmaktadır. Ayrıca, LSTM'nin kayıp fonksiyonu değerleri 0.05'in altında kalırken, DNN'nin değerleri 0.1'in altındadır. Bu sonuçlar, **Şekil 5.15**'te gösterilen stratejik mimari ile birlikte, şebekeye bağlı PV sistemleri için güneş MPPT'sini tahmin etmede LSTM'nin yüksek düzeydeki doğruluğunun altını çizmektedir.



**Şekil 5.15.** LSTM ağının artan epoklarla eğitim ilerlemesi

**Şekil 5.16**, LSTM modelinin eğitim sonuçlarını göstermektedir. LSTM ağı, **Şekil 5.16(a)**'da gösterildiği gibi 1 milyon girdi örneğinin (G ve T değişkenleri dahil) ilk %80'i ve karşılık gelen hedef değişkenler ( $V_{mp}$ ) üzerinde eğitilir. Bu girdiler (G ve T) eğitilmiş LSTM ağına beslenir ve ardından tahmin edilen çıktı, **Şekil 5.16 (b)**'de gösterildiği gibi eğitim hatasını hesaplamak için gerçek eğitim hedefiyle karşılaştırılır. **Şekil 5.16 (c)**'de


gösterilen eğitim hatası 0.048 gibi küçük bir aralıktadır, bu da hatanın son derece küçük olduğunu ve tahmin edilen sonucun gerçek çıktı ile yaklaşık olarak aynı olduğunu gösterir. Bu doğruluk, diğer görünmeyen veri kümeleriyle gelecekteki testler için modelin sağlamlığını garanti eder. LSTM'nin mükemmel performansı ve güvenilirliği göz önüne alındığında, bu sonuçlar şebekeye bağlı PV sistemleri için MPPT için uygun bir yöntem olarak eğitilmiş bir LSTM kullanımını doğrulamaktadır.



Şekil 5.16. LSTM kullanarak (a) eğitim girdileri, (b) tahmin edilen hedef ve (c) gerçek ve tahmin edilen hedef Vmp arasındaki eğitim hatası

#### 5.4.2.4. LSTM Ağının Test Edilmesi

Şekil 5.17(a)'da gösterildiği gibi eğitilmiş LSTM'ye verilir ve bu görünmeyen test edilmiş veri üzerinde tahmin edilen çıktı ile test hedefi Şekil 5.17 (b)'de gösterildiği gibi karşılaştırılır. Sonuçlar, Şekil 5.17 (c)'de gösterildiği gibi sürekli olarak 0,048 hata aralığında kalmıştır. Yaklaşık 0,048 olan çok düşük hatalar da modelin geçerliliğini teyit etmekte ve gerçek dünyadaki güvenilirliğini ve PV sistemlerinin MPP'sindeki gerilimi yüksek doğrulukla optimize etme potansiyelini sağlamaktadır.



Şekil 5.17. (a) Test girdileri, (b) gerçek test hedefine karşı öngörülen hedef ve (c) LSTM kullanılarak gerçek ve öngörülen hedef Vmp arasındaki test hatası

#### 5.4.3. DNN ve LSTM Modellerinin Performans Değerlendirme Karşılaştırması

Önceki adımlarda, her iki DL modeli (LSTM, DNN) için (a) veri toplama, (b) normalleştirme, (c) görselleştirme, (d) bölme, (e) ağ tasarımı, (f) hiper parametrelerin seçimi, (g) eğitim ve (h) her iki DL modelinin test edilmesi dahil olmak üzere tüm önemli adımlar sırayla gerçekleştirilir. Şimdi, her iki modelin performansını karşılaştırma zamanı. ML ve DL'de MSE, RMSE, MAE ve R-kare gibi performans parametreleri modelin güvenilirliğini, doğruluğunu ve verimliliğini değerlendirmek için çok önemlidir (Dewang Chen et al., 2022).

Performans sonuçlarına geçmeden önce, performans metriklerinin bir özeti vurgulanmıştır. MSE, gerçek ve tahmin edilen değerler arasındaki ortalama karesel sapmanın bir ölçüsüdür ve modelin genel doğruluğu hakkında bilgi sağlar. MSE'den türetilen RMSE, tahmin edilen ve gerçek değerler arasındaki karesel farkların ortalamasının karekökünü temsil eder ve bir tahmin modelinin tahminlerinin

doğruluğunun bir ölçüsünü sağlar. MAE, tahmin edilen hedef ile gerçek hedef arasındaki ortalama mutlak hatayı hesaplar. Model uyumu, girdilerden tahmin edilebilen hedef varyansını analiz eden R-kare (R<sup>2</sup>) ile belirlenir. Genel olarak, bu ölçütler ML ve DL modellerinin performansının belirlenmesinde önemli bir rol oynamaktadır. DNN ve LSTM modellerinin hem ham veriler hem de normalleştirilmiş veriler için performansı **Çizelge 5.3**'te listelenmiştir.


**Çizelge 5.3.** Hem ham hem de normalleştirilmiş veriler için DNN ve LSTM performans parametrelerinin karşılaştırılması.

| Performans Metrikleri                 | Norm LSTM | Orijinal LSTM | Norm DNN | Orijinal DNN |
|---------------------------------------|-----------|---------------|----------|--------------|
| <b>Ortalama Kare Hatası (MSE)</b>     | 0.0023295 | 0.046674      | 0.18561  | 3.7189       |
| <b>Ortalama Karekök Hatası (RMSE)</b> | 0.048265  | 0.21604       | 0.43083  | 1.9285       |
| <b>Ortalama Mutlak Hata (MAE)</b>     | 0.033978  | 0.15209       | 0.33843  | 1.5148       |
| <b>R-kare (R<sup>2</sup>)</b>         | 0.99768   | 0.99768       | 0.80438  | 0.80438      |

Kolay bir karşılaştırmalı analiz için, DNN ve LSTM'nin performansı arasındaki çubuk grafik tabanlı grafiksel analiz **Şekil 5.18**'te gösterilmiştir. 10. Grafiksel sonuçlar, LSTM'nin MSE'sinin 0,0023295 iken DNN'ninkinin 0,18561 olduğunu; RMSE ve MAE'nin sırasıyla 0,048265 ve 0,43083 ve 0,033978 ve 0,33843 olduğunu ve R<sup>2</sup>'nin sırasıyla 0,99768 ve 0,80438 olduğunu göstermektedir.

Bu sonuçlar, LSTM'nin DNN'den daha iyi performans gösterdiğini ve önemli doğruluk, hassasiyet ve tahmin yeteneği ortaya koyduğunu göstermektedir. Bunun nedeni, LSTM'nin depolama biriminin bilgiyi daha uzun süre saklayabilmesi ve böylece sürekli verilerin işlenmesini kolaylaştırmasıdır. Konuşma tanıma, dil çevirisi ve borsa tahmini gibi sürekli veri içeren görevlerde, DNN'ler bu yetenekten yoksun oldukları ve girdileri yalnızca bağımsız olarak işleyebildikleri için daha az etkilidir. Tüm metriklerde, LSTM'nin doğruluğu ideal doğruluğa çok yakındır, bu da LSTM'nin verilerdeki karmaşık örüntüleri yakalamadaki etkinliğini vurgulamakta ve bu çalışmada DNN'den daha iyi performans gösterdiğini kanıtlamaktadır.






**Şekil 5.18.** Her iki DL (DNN ve LSTM) Ağı arasındaki performans karşılaştırma analizi.

Eğitilen LSTM ve DNN modelleri artık hazırdır ve önerilen 100 kW şebeke bağlantılı PV sisteminde kullanılmak üzere Simulink'e aktarılmıştır.

### 5.5. Şebekeye Bağlı PV için MPPT Kontrolü


Bu çalışmanın odak noktası, şebekeye bağlı PV sistemler için LSTM tabanlı bir MPPT kontrolörü geliştirmek ve bunu FF DNN tabanlı geleneksel P&O ve DL tabanlı MPPT kontrolörleri ile karşılaştırmaktır.



**Şekil 5.19.** 100 kW şebekeye bağlı PV sisteminin Simulink modeli

Önerilen modelin Simulink diyagramı **Şekil 5.19'**de gösterilmektedir. MPPT kontrolörünün (LSTM, DNN, P&O) her biri ayrı ayrı modele entegre edilmiş ve simülasyon sonuçları elde edilmiş ve ardından karşılaştırılmıştır. DL tabanlı kontrolörlerin (LSTM, DNN) veri işleme görevleri arasında veri toplama, veri işleme, eğitim ve test yer almaktadır. P&O yöntemi verilerle ilgilenmediği için doğrudan MATLAB M-File kodlaması ile kodlanmıştır. Simulink fonksiyon blokları kullanılarak, P&O doğrudan PV sisteminin Simulink modeline uygulanır ve şebekeye bağlı PV sisteminin Simulink modeliyle entegre edilir. P&O yönteminin ayrıntılı açıklaması, blok diyagramı ve sözlü kodu **Bölüm 3'**te verilmiştir.

FF DNN yönteminde, eğitilen DNN modeli gensim komutu kullanılarak Simulink'e aktarılır, ancak LSTM ağı bu tür yerleşik gensim komutlarını kabul etmez. Bu nedenle, LSTM ağı M-File Coding kullanılarak tasarlanır ve ardından önceden işlenmiş veri kümesi Deep Network Designer'a (DND) yüklenir. DND araç kutusu, eğitilmiş LSTM modelini Simulink'e aktarmak için esneklik sunar ve PV sisteminin şebekeye bağlı Simulink modeliyle sorunsuz entegrasyon sağlar.




**Şekil 5.20.** Şebekeye bağlı PV sistemindeki tüm sinyallerin görselleştirilmesi ve çizilmesi

Simülasyon sonuçları önce Simulink'te analiz edilir ve Scope bloğu ile görselleştirilir. Sinyal verileri daha sonra "toworkspace" Simulink bloğu aracılığıyla workspace'e gönderilir. Bu işlem, **Şekil 5.20'**de gösterildiği gibi, şebekeye bağlı PV sisteminin her aşaması için akım, gerilim ve güç gibi değişkenler için simülasyon sonuçları ve diyagramları oluşturmak için kullanılır.

### 5.5.1. Simulink'te Şebekeye Bağlı PV Sistemin MPPT'si için Giriş Sinyalleri

Önceden eğitilen modeller (LSTM, DNN) veri setinin %20'si üzerinde test edilmiştir. Şimdi, eğitilen modeller Simulink'e aktarılarak 100 kW şebeke bağlantılı PV sisteminin Simulink modeliyle entegre edilmesi modellenmektedir. G ve T sinyalleri toplam 1,5 birim örnekleme süresi ( $T_s$ ) boyunca uygulanır ve powergui bloğunda örnekleme süresi  $1e^{-6}$  olarak varsayılır, bu giriş sinyalleri bu  $T_s$  süresinde yaklaşık 1,5 milyon örnekleme değerine sahiptir. Performansını ve davranışını kapsamlı bir şekilde değerlendirmek için Şekil 5.21'de gösterildiği gibi G ve T değişken sinyalleri kullanılmıştır. Sinyaller, her biri x ekseninde 0,15'lik artışlardan sonra G ve T girişlerinin belirli bir davranışına karşılık gelen 9 farklı duruma (1'den 9'a) ayrılmıştır.



Şekil 5.21. Simulink ortamında MPPT kontrolörlerine (LSTM, DNN, P&O) G ve T giriş sinyalleri

Bu yaklaşım, değişen G ve T koşulları altında modelin tepkisinin ayrıntılı bir şekilde değerlendirilmesine olanak tanır. Bu, MPPT kontrolörünün farklı çevresel senaryolar altındaki davranışına ilişkin değerli bilgiler sağlar. Önerilen modelin analizini kolaylaştırmak için 9 durum aşağıdaki gibi düzenlenmiştir:

- **Durum 1: STC -  $G = 1000 \text{ W/m}^2$ ,  $T = 25 \text{ }^\circ\text{C}$**

Bu ilk durumda, her iki giriş (G, T) de STC değerlerinde tutulmuştur. Çünkü bu tezde PV dizisi maksimum 100 kW güç üretmektedir. Bu durum, STC koşulunda her bir

MPPT denetleyicisi tarafından üretilen maksimum gücün analiz edilmesine yardımcı olur.

- **Durum 2: Azalan G, T = 25 °C**

Bu ikinci durumda, T değeri STC'de sabit kalmakta ve azalan G'nin solar PV dizisinin çıkış gücü üzerindeki etkisini analiz etmek için G doğrusal olarak azalmaktadır.

- **Durum 3: Artan G, T = 25 °C**

Bu üçüncü durumda, T hala STC değerinde sabittir ve G şimdi artan G'nin çıkış PV gücü üzerindeki etkisini analiz etmek için doğrusal olarak artmaktadır.

- **Durum 4: G = 1000 w/m<sup>2</sup>, T 80 °C'ye Yükseltildi**

Bu dördüncü durumda, G değeri STC değerinde sabit kalırken, T en yüksek değerine yükselir ve bu da yüksek sıcaklığın PV dizisinin performansı üzerindeki etkisini analiz etmeye yardımcı olur.

- **Durum 5: G = 1000 w/m<sup>2</sup>, T Doğrusal Olarak Azalır**

Bu beşinci durumda, G değeri STC değerinde sabit tutulmuş ve T değerindeki azalmanın PV'nin çıkış gücü üzerindeki etkisini incelemek için T değeri azaltılmıştır.

- **Durum 6: G = 1000 w/m<sup>2</sup>, T Doğrusal Olarak Artıyor**

Bu altıncı durumda, G değeri STC'de sabit kalmakta ve artan T değerinin PV dizisinin çıkış gücü üzerindeki etkisini gözlemlemek için T doğrusal olarak artmaktadır.

- **Durum 7: G = 500 w/m<sup>2</sup>, T = 80 °C**

Bu yedinci durumda, azalan G ve artan T değerlerinin PV gücü üzerindeki etkisini araştırmak için G maksimum STC değerinden STC değerinin yarısı olan 500'e düşürülmüş ve T STC'nin üzerinde artırılmıştır.

- **Durum 8: T = 25°C, G Rastgele Değişir**

Bu sekizinci durumda, T STC değerinde sabit kalmakta ve G değişiminin PV gücü üzerindeki etkisini incelemek için G rastgele değişmektedir (artmakta ve azalmaktadır).


- **Durum 9: G = 1000 /m<sup>2</sup>, T Rastgele Değişir**

Bu dokuzuncu durumda, G değeri STC değerinin yarısında (500 w/m<sup>2</sup>) sabit tutulur ve T değerindeki değişimin PV gücü üzerindeki etkisini fark etmek için T rastgele değişir (artar ve azalır).

Bu bölümdeki analizin geri kalanında, yukarıda açıklandığı gibi G ve T girdilerinin belirli değerlerini ve davranışlarını temsil eden durum 1 veya durum 2 gibi belirli bir durumu belirtmek için yalnızca durum numarası yazılmıştır.

### 5.5.2. G ve T Sinyallerine Karşı Solar PV Ölçümü

Bu giriş parametreleri (G, T) ile PV dizisinin çıkışı (akım, gerilim ve güç) arasındaki ilişkinin kapsamlı bir analizi Şekil 5.22'de analiz edilmiştir. Şekil 5.22 (a) 0 ila  $1.000 \text{ W/m}^2$  arasında değişen G giriş sinyalini temsil etmektedir. Şekil 5.22 (b) 20 ila  $80^\circ\text{C}$  arasında değişen T giriş sinyalini göstermektedir.



Şekil 5.22. Değişken girişlere (G, T) göre solar PV modül çıkışları (V, I, P)

Bu girişler PV dizisine uygulandıktan sonra, SunPower TS-SPR-315 PV modülünden PV dizisinin voltajı, akımı ve gücü dahil olmak üzere ölçülen çıkışlar toplanır. PV modülünün gerilimi  $V_{pv}$  250 ila 280 volt arasında değişir, solar PV akımı, sırasıyla Şekil 5.22 (c) ile (e)'de gösterildiği gibi PV dizisinden 100 kW güç sağlamak için PV gerilimindeki değişikliklere göre değişir.

MPPT entegrasyonuna geçmeden önce, yukarıda açıklanan 9 duruma göre girişlerin (G, T) davranışı yukarıdaki sonuçlardan analiz edilebilir. G'nin PV'nin çıkış


gücü ile doğru orantılı olduğu ve T'nin PV dizisinin çıkış gücü ile ters orantılı olduğu ve STC'de önerilen PV modülünün 99.87 kW güç ürettiği görülebilir. Bu istatistikler MPPT kontrolörünün optimizasyonu için önemli girdilerdir ve bir sonraki alt bölümde daha ayrıntılı olarak ele alınacaktır. Farklı koşullar altında gerçek çıkış gücünü (yaklaşık 100 kW) izleyerek, modelin doğruluğu ve uyarlanabilirliği sağlanır ve bu da MPPT kontrolörlerinin entegrasyonu için önemli bilgiler sağlar.

### 5.5.3. Stack LSTM, FF-DNN ve P&O MPPT Kontrolörlerinin Karşılaştırmalı Sonuçları

Üç farklı MPPT kontrolörünün simülasyon performansı: Stack LSTM, FF DNN ve P&O Simulink MATLAB 2023© kullanılarak gerçekleştirilmiş, karşılaştırmalı sonuçlar **Şekil 5.23**'te sunulmuştur. Performans değerlendirmesi, **Şekil 5.23** (a) ve (b)'de özetlenen belirli girdilere göre performanslarına odaklanmaktadır.


Bu tezde, PV eğrisi üzerinde MPP'deki ( $V_{mp}$ ) voltajı çıkaran MPPT çıkarımı için voltaj kontrol yöntemi benimsenmiştir (**bkz. Bölüm 4**). Amaç, PV gerilimini ( $V_{pv}$ ) MPP'nin bulunduğu gerilimde çalıştırmaktır. Bu nedenle,  $V_{mp}$  çıkışı MPPT kontrolörleri tarafından  $V_{pv}$  ile karşılaştırılır ve fark hata sinyali, önerilen modelin ilk aşamasında yükseltici tip DC-DC dönüştürücüde kullanılan 5 kHz IGBT anahtarının görev döngüsünü kontrol eden PI kontrolörüne beslenir.

TS-SPR-315 PV modülü tarafından üretilen hesaplanan güç yaklaşık 102 kW'tır, ancak bu PV modülü tarafından girişlerin STC'sinde üretilen gerçek ölçülen güç 99,87 kW'tır. Performans değerlendirme parametrelerinin sonuçları, stack LSTM'nin eğitim ve test hatalarının FF-DNN'ninkilerden daha küçük olmasını sağlamıştır. Bu nedenle, LSTM (98,84 kW) MPPT kontrolörü kullanılarak elde edilen maksimum çıkış gücü, **Şekil 5.24**'te gösterildiği gibi DNN (96,32 kW) ve P&O (94,05 kW) kontrolörlerinden daha yüksektir. Ayrıca, DL algoritmaları (LSTM ve DNN) 1 milyon veriden oluşan büyük bir veri kümesi üzerinde eğitildiğinden, eğitim bilgilerine dayanarak hedefe erken karar verebilirler ve P&O dalgalanırken MPP etrafında dalgalanmazlar, bu da P&O MPPT yönteminin ortalama gücünün daha düşük olmasına neden olur.



Şekil 5.23. Stack LSTM, FF-DNN ve P&O MPPT Kontrolörleri arasında karşılaştırmalı analiz

Buna ek olarak, FF DNN'ler yalnızca ileri bilgileri işler, ancak geri bildirim süreci ve bellek birimleri LSTM'nin karmaşık kalıpları hızlı bir şekilde öğrenmesine ve maksimum performans elde etmesine olanak tanır.




Şekil 5.24. STC'de LSTM, DNN ve P&O MPPT Kontrolörleri arasındaki maksimum güç çıkarma karşılaştırması.

Bu nedenle, stack LSTM diğer MPPT kontrolörlerinden daha iyi performans gösterir ve diğer kontrolörlere kıyasla daha fazla doğruluk ve daha az salınım ile daha yüksek güç sunar. Önerilen stack LSTM tabanlı MPPT kontrolörünün baskınlığı sağlandıktan sonra, önerilen stack LSTM MPPT kontrolörü kullanılarak inverter kontrol sonuçları elde edilmiştir.

#### 5.5.4. Birinci Aşamada MPPT Entegre Yükseltici tip DC-DC dönüştürücü Çıkış Gerilimi

Çift aşamalı şebeke bağlantılı PV sistemlerde, yükseltici tip DC-DC dönüştürücü ilk aşamadaki en önemli elemanlardan biridir. Bu tezde, MPPT kontrolörleri Şekil 5.25'te gösterildiği gibi değişen  $G$  ve  $T$  giriş sinyallerine göre  $V_{mp}$ 'yi belirleyerek PV dizisinin maksimum gücünü elde eder.



Şekil 5.25. Değişken girişlere ( $G$ ,  $T$ ) göre PV dizinin hedef gerilimi, görev döngüsü ve yükseltme gerilimi




Ardından, hesaplanan  $V_{mp}$  ile **Şekil 5.25**'te gösterilen gerçek FV çıkış gerilimi ( $V_{pv}$ ) karşılaştırılarak bir hata sinyali üretilir ve bu hata PI denetleyiciye verilir. ( $V_{mp} - V_{pv}$ ) hatasına yanıt olarak PI denetleyici, FV sistemin ayrılmaz bir bileşeni olan yükseltici tip DC-DC dönüştürücünün görev döngüsünü (D) ayarlar. Spesifik olarak, D'nin artırılması yükseltici tip DC-DC dönüştürücü çıkış voltajını artırır ve böylece PV çalışma noktasını I-V eğrisinin sağ tarafına doğru kaydırır. Tersine, D'nin azaltılması çalışma noktasını sol tarafa kaydırır. Bu dinamik ayarlama, sistemin çalışma noktasının  $V_{mp}$  ile hizalanmasını sağlayarak fotovoltaik diziden maksimum güç elde edilmesine olanak sağlar.

MPPT kontrolörü tarafından kontrol edilen  $V_{mp}$  250 ila 280 arasında değiştiğinden, yükseltici tip DC-DC dönüştürücü neredeyse sabit 800 V'ta tutulan düzenlenmiş bir doğru akım (DC) bağlantı voltajı sağlar. Bu kontrol stratejisiyle, değişen G ve T koşulları altında PV güç çıkarımını optimize etmek mümkündür.  $V_{mp}$ 'yi sürekli izleyerek ve hata güdümlü bir yöntem kullanarak yükseltici tip DC-DC dönüştürücünün görev döngüsünü (D) ayarlayarak, bu yaklaşım sistemin en yüksek verimlilikte çalışmasını ve sonuçta maksimum güç çıkışına ulaşmasını sağlar.

## 5.6. Şebekeye Bağlı PV'nin İnverter Kontrolü

İnverter, şebekeye bağlı bir PV sistemde PV sistem ile şebeke arasında bir arayüz olarak çok önemli bir rol oynar. İnvertör kontrol sisteminin ana hedefleri, PV dizisinden şebekeye aktif güç akışını kontrol etmek ve şebeke ile senkronize tutmak ve DC bağlantı voltajını düzenlemektir.



**Şekil 5.26.** Şebekeye bağlı inverter kontrolünün Simulink modeli

PI kontrolörleri ile vektör kontrolü, PWM üretimi ve PLL senkronizasyonu gibi gelişmiş kontrol teknikleri, yüksek kaliteli AC gücü sağlamak için gereklidir. İnvertör kontrolü, kapalı döngü kontrolü yoluyla aktif akım ( $I_d$ ) bileşenini düzenleyerek PV jeneratör tarafından üretilen DC bağlantı voltajını sabit tutar. Reaktif güç, reaktif akımın ( $I_q$ ) sıfıra ayarlanmasıyla ortadan kaldırılır. Şebeke senkronizasyonu, eviricinin çıkış voltajı ve frekansının bir faz kilitli döngü (PLL) aracılığıyla şebekeyle eşleştirilmesiyle elde edilir. Ayrıca, modülasyon indeksi ve anahtarlama modları, istenen genlikte temiz bir sinüzoidal dalga formu çıkışı için kontrol edilir. İnvertör kontrol bölümünün Simulink diyagramı **Şekil 5.26**'da sunulmuştur.

Gelişmiş inverter kontrolü, güç kalitesini korurken PV sisteminin şebekeye sorunsuz bir şekilde entegre edilmesini sağlar. Bu nedenle, güvenilir, yüksek performanslı inverter kontrolü istikrarlı, verimli bir şebekeye bağlı PV sistem için gereklidir. Bu alt bölümde, inverter kontrolüne ilişkin sonuçlar ve tartışma verilen sırayı takip etmektedir:

- **DC Bağlantı Gerilim Regülasyonu**

Önceki bölümde, PV dizisinin maksimum gücü MPPT kontrolörleri kullanılarak elde edilmiştir. Elde edilen PV gerilimi 800 V'a yükseltilir. Bu yükseltme gerilimi DC bağlantı gerilimidir. Gerilim, akım ve gücün yüksek kaliteli AC dalga şekillerini üretmek için DC bağlantı geriliminin düzenlenmesi ve kontrolü gereklidir.

- **NPC İnvertör Çıkış Dalga Formları**

İnverter, PV dizisi tarafından üretilen DC gücünü AC gücüne dönüştürmek için hayati bir rol oynar. Amaç, inverter gerilimini ve akımını daha az harmonik ile üretmektir.

- **Şebeke Senkronizasyonu**

Şebeke senkronizasyonu, şebekeye bağlı bir PV eviricinin çıkış geriliminin faz açısının ( $\theta$ ) şebeke gerilimi ile hizalanmasını ifade eder. Bu hizalama kesintisiz güç aktarımı, şebeke kararlılığının korunması ve şebeke standartları ve yönetmeliklerine uyum için gereklidir.

- **Direkt ve Kuadratik Eksen Akımları**

Şebekeye bağlı bir PV sistemindeki doğru eksen ( $I_d$ ) ve karesel eksen ( $I_q$ ) akımları, senkronize olarak dönen bir referans sistemindeki akım bileşenlerini temsil eder.  $I_d$ , şebeke gerilimiyle aynı açıdayken,  $I_q$  şebeke gerilimine dik olan bir karesel akımdır.  $I_d$  ve  $I_q$ 'nın kontrolü, verimli güç aktarımı ve şebeke stabilizasyonu için şebekeye beslenen aktif ve reaktif gücün hassas bir şekilde düzenlenmesini sağlar.

- **Aktif ve Reaktif Güç Aktarımı**


NPC inverterde  $I_d$  ve  $I_q$  kontrol akımlarının yanı sıra şebeke gerilim ve akım sinyalleri, PV sistem ile şebeke arasındaki aktif ve reaktif güç alışverişinin hassas bir şekilde kontrol edilmesini sağlar. PV gücünün şebekeye tek bir güç faktöründe doğru şekilde aktarıldığını doğrulayarak verimli enerji aktarımı sağlar. Her bir adımın ayrıntılı sonuçları ve tartışması aşağıda sunulmuştur:

### 5.6.1. NPC İnvörtörün Giriş (DC Link) ve Çıkış Gerilimi

Stack LSTM, FF-DNN ve P&O MPPT denetleyicisi de dahil olmak üzere bu tezde ele alınan tüm kontrolörler arasında, kalan invertör kontrol simülasyonlarının sonuçlarını elde etmek için en verimli ve doğru yığın LSTM MPPT kabul edilir. 100 kW'lık bir PV sisteminin şebeke entegrasyonu iki aşamalı bir süreçte gerçekleştirildi. İlk aşamada, daha önce açıklandığı gibi, PV sistemi, takviye dönüştürücü ve MPPT kontrolörü ana unsurlardır. PV sistemi 250 ila 280 volt voltajlarda çalışır ve değişken  $G$  (0-1000)  $W/m^2$  ve  $T$  (20-80 °C) varlığında 350 ila 400 amper akım üretir. Değişken  $G$  ve  $T$ 'nin varlığında, stack LSTM MPPT kontrolörü, takviye dönüştürücünün görev döngüsünü ( $D$ ) ayarlar ve düzenlenmiş DC bağlantı voltajının ( $V_{dc}$ ) minimum dalgalanmalarla 800 voltluk belirli bir değerde tutulmasında rol oynar. İkinci aşamada, akım ve gerilim kontrol yöntemlerini kullanarak DC bağlantı voltajını daha fazla kontrol etmek ve PV sisteminden şebekeye aktif güç sağlamak için bir invertör kontrol stratejisi kullanılır.

Düzenlenmiş veya Kontrollü DC bağlantı voltajı  $V_{dc}$  (800 V), aynı zamanda NPC invertörünün girişi olan takviye dönüştürücünün çıkışıdır.  $V_{dc}$ , çıkış faz gerilimlerinin büyüklüğünü hassas bir şekilde düzenleyen 3 fazlı, 3 seviyeli bir NPC invertöre, yani


$V_{dc}/2$  (+400), 0 ve  $-V_{dc}/2$  (-400) beslenir, seviyelerdeki bu artış harmonikleri azaltır ve iyi bir güç dönüşümü sağlar ( Bektaş ve Karaca, 2022).



Şekil 5.27. 3 seviyeli NPC invertirin çıkışındaki 3 fazlı voltaj ve akım.

İnverter, 400 voltluk bir çıkış voltajı ve 201 amperlik bir hat veya faz akımı üretmek üzere tasarlanmıştır (Y-bağlıda hat ve faz akımı aynı kalır), ve Şekil 5.27'da gösterildiği gibi invertirin çıkışında verilen 100 kW'lık beklenen güç gereksinimine karşılık  $P = 3 * V_{rms} * I_{line}$ ,  $3 * (P = 3 * (\frac{400}{\sqrt{2}}) * (\frac{201}{\sqrt{2}}))$ , = 98.4 kW) gelir.

Önerilen stack LSTM tarafından PV tarafından çıkarılan 98,7 kW gücün 98,4 kW gücünün, invertörün çıkışına aktarıldığı anlamına gelir. Bu konfigürasyon, 400 V şebeke standartlarına uygunluğu sağlar. Ek olarak, NPC invertör, invertör anahtarlarının IGBT anahtarlama durumlarını düzenleyerek 201 amperlik gerekli akım çıkışına ulaşır. Voltaj ve akımın bu hassas kontrolü, PV'den mikro şebekeye kesintisiz ve verimli güç aktarımı sağlayarak onu şebekeye bağlı PV sistemleri için güçlü bir çözüm haline getirir. İnverter kontrolünün ayrıntılı bir açıklaması Bölüm 4'te verilmiştir. NPC invertör, standart test koşulları (STC) altında 400 V'luk bir hat voltajını korur, Şekil 5.28'de gösterildiği gibi Y bağlantılı şebeke bağlantısı nedeniyle hat akımı 144 A'lık bir hat akımına eşdeğer kalır.



Şekil 5.28. İnverterin çıkışındaki faz hattı voltajı ve akımı.

Güç kalitesi standartları, güç sisteminin kararlılığını ve güvenilirliğini sağlamak için gereklidir. Bu standartlar, ülkeden ülkeye değişebilen ters voltaj ve akım dalga biçimlerinde THD için belirli limitler içerir. Güç kalitesi ağ kodları için uluslararası standart, THD değerlerini %5'e eşit veya daha az önerir. Türkiye'de, Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) aynı THD limitlerini sunan güç kalitesi standartlarını düzenler ve Pakistan'da aynı THD'ye izin verilir, Ulusal Elektrik Düzenleme Kurumu (NEPRA) elektrik sektörünü denetler ve güvenilir bir şebeke sağlamak için güç kalitesi yönergeleri ve limitleri belirler. Önerilen invertör, Türkiye ve Pakistan dahil olmak üzere uluslararası standartların kriterlerini karşılamaktadır.

### 5.6.2. Değişken Girişlere (G, T) Göre Şebeke Gerilimi ve Akımı

230 V faz gerilimi değeri, Avrupa'nın çoğu, Asya ve Afrika ve Güney Amerika'nın bazı bölgeleri de dahil olmak üzere dünyanın birçok ülkesinde düşük-orta gerilim elektrik dağıtımı ve çeşitli endüstriyel uygulamalar için kullanılan standart bir gerilim seviyesidir (Gullu et al., 2022). Bu gerilimin kullanımı, kabloda daha düşük enerji kayıpları ve daha az bakır kullanımı gibi çeşitli avantajlar sunar. NPC inverterler, 400 V hat ve 144 A şebeke standartlarına uygun olarak belirli çıkış gerilimleri ve akımları üretmek için önemli bir rol oynamaktadır.


Değişken girişlere (G, T) dayalı olarak 230 V faz geriliminde ve 144 A hat akımında çalışan bütünleşmiş bir mikro şebeke sisteminde akım ve gerilim kontrol döngülerini kullanan bir düşme kontrol stratejisi kullanılır. Düşme (droop) kontrolünde reaktif akımın sıfır olduğu varsayılır, bu nedenle bütünleşmiş sistemde reaktif yük akışı olmayacaktır. Bu üç fazlı sistem için gerçek güç (P), reaktif gücün olmadığı  $P = 3 \times V_{rms} \times I_{rms} \times \cos(\theta)$  kullanılarak elde edilir, bu nedenle şebeke voltajı ve akımı  $\cos(0) = 1$  içeren fazdadır ve optimum aktif güç aktarımı için birim güç faktörünü korur. Mikro şebekenin kararlılığı, DC bara voltaj regülasyon kontrolüne, frekans/voltaj regülasyonuna ve güç paylaşımına dayanır. Bu stratejiler, sistemi maksimum aktif güç aktarımı için optimize eden, verimliliği ve güvenilirliği artıran belirli değerler tarafından yönlendirilir.

### 5.6.3. Direkt ve Kuadratür Eksen Akımları

PV dizisinden üç fazlı (400V/144A) bir şebekeye aktif güç sağlamak için, yükseltici dönüştürücü önce PV çıkış voltajını (250-280 V) 800 V'a yükseltir. Bu voltaj,  $i_d$  ve  $i_q$  akımlarını kontrol etmek için anahtarlama oranını ayarlayan PI kontrollü bir NPC invertöre beslenir. PI kontrolü, çıkış voltajı vektörünü şebeke voltajı vektörüyle karşılaştırarak bir hata sinyali üretir. Çıkış voltajı daha yüksek veya daha düşükse, inverterin modülasyon indeksi ve görev döngüsü kontrol edilerek 800V referansına göre düzenlenir.

Inverterin çıkışında faz voltajı 230V, karşılık gelen hat akımı 142.4A ve hat voltajı 400V'dir. Y bağlantılı bir konfigürasyonda hem hat hem de faz akımları aynıdır. NPC invertördeki giriş gücü 98.7kW DC, çıkış gücü ise 98.4kW AC'dir. Ayrıca,  $I_d$  ve  $I_q$  değerleri Park dönüşümü ile elde edilir:  $I_d = 144\angle 0^\circ A$  ve  $I_q = 0\angle 0^\circ A$ , birim güç


faktöründe 144A'lık bir aktif akımı gösterir. Bu dönüşüm, **Şekil 5.29**'da gösterildiği gibi aktif ve reaktif güç bileşenlerini verimli bir şekilde ayırır.



**Şekil 5.29.** İnverter kontrol bölümünde d eksen ve q eksen akımlarının gösterilmesi

#### 5.6.4. PV Entegre Şebekeye Sağlanan Aktif Reaktif Güç

Bu çalışmada, stack LSTM, MPPT'de FF-DNN ve P&O algoritmalarından daha iyi performans göstermektedir. LSTM MPPT'nin doğruluğundan yararlanan inverter kontrol ayarları, şebeke koşullarına uygun istenen sonuçları elde etmek için optimize edilmiştir. Bu çalışmada kullanılan değişken girdiler sırasıyla **Şekil 5.30**'da gösterildiği gibi G ve T'dir. PV modülü tarafından üretilen toplam güç 99,86 kW'tır ve istiflenmiş LSTM MPPT 98,7 kW çıkardı ve ardından 98,4 kW aktif gücü verimli bir şekilde şebekeye aktardı ve **Şekil 5.30**'da gösterildiği gibi olağanüstü verimliliğinin altını çizdi. Üretilen ve iletilen güç arasındaki küçük fark, potansiyel olarak olası güç kaybının yarı iletken kayıplarından, anahtarlama kayıplarından ve direnç kayıplarından kaynaklanabileceğini gösterir.



Şekil 5.30. PV dizisinden mikro şebekeye aktarılan aktif ve reaktif güç

Bu tez çalışmasında, mikro şebeke entegrasyonu için üstün verimliliği ve düşük anahtarlama kayıpları ile bilinen 3 seviyeli bir NPC invertör kullanılmıştır. Mikro şebeke, STC'de 400 voltluk standart üç fazlı voltajda ve 144 amperlik bir akımda çalıştı. DC bağlantı voltajı, her ikisi de ilgili PI kontrolörleri tarafından düzenlenen bir dahili akım kontrol döngüsü ve bir harici voltaj kontrol döngüsü tarafından kolaylaştırılan invertör kontrolü kullanılarak 800 voltta düzenlenir. Bu kontrolörler, şebeke kararlılığı için hayati önem taşıyan hassas voltaj regülasyonu sağladı. Sinüzoidal PWM kullanıldı ve harmonik içerik bir LCL filtresi ile daha da minimize edildi. Toplam Harmonik Bozulma (THD) %5'in altında tutularak Pakistan, Türkiye ve uluslararası şebeke kodu standartlarını karşıladı. Bu iyileştirmeler yalnızca güç aktarımını optimize etmekle kalmadı, aynı zamanda sıkı şebeke düzenlemelerine uyumu sağlayarak mikro şebekenin güvenilirliğini ve performansını da artırdı.



## 5.7. Bölüm Özeti

Bölüm 5'te, ilk olarak bir derin öğrenme modeli için en önemli adım olan 1 milyon veri noktası içeren bir veri kümesi toplandı. Normalleştirme, z-skoru kullanılarak gerçekleştirilir, ardından kutu grafikleri, histogramlar ve korelasyon analizi kullanılarak veri analizi yapılır. Eğitim için %80 veri ve test için kalan %20 veri kullanmak için 80/20 bölme kuralına uyulur. LSTM ve DNN gibi derin öğrenme modelleri, MSE, RMSE, MAE ve R2 gibi metrikler kullanılarak MPPT performansı için geliştirilmiş ve değerlendirilmiştir. Karşılaştırma sonuçları, LSTM modelinin güç çıkarımını en üst düzeye çıkarmada daha avantajlı olduğunu göstermektedir. Eğitilmiş LSTM ve DNN modeli Simulink'e entegre edildi ve karşılaştırma sonuçları, stack LSTM MPPT'nin FFDNN ve P&O MPPT'lerden daha iyi performans gösterdiğini gösterdi. Stack LSTM'nin hakimiyetini kurduktan sonra, önerilen LSTM modeli kullanılarak invertör kontrolü için daha fazla sonuç ve tartışma gerçekleştirildi. Değişken G ve T giriş sinyallerinin varlığında, PV gücü, takviye dönüştürücü kullanılarak 800V DC'ye yükseltilir ve bu DC bara voltaj regülasyonu hem MPPT kontrolörü hem de inverter kontrolünün droop kontrolörü (Akım ve gerilim kontrolörü) katkısıyla üretilir. Bu regüle edilmiş DC bağlantı voltajı, üç aşamalı NPC invertöre beslenir ve tek tip güç faktörü ile şebeke bağlantısı elde etmek için 400V/144A'ya evrilir. Son olarak, önerilen LSTM stackı kullanılarak, PV dizisinden mikro şebekeye (400 V hattan hatta veya 230 V hattan nötre) 98,7 kW aktif güç aktarımı sağlandı, bu da düşük-orta gerilim elektrik dağıtımı için kullanılan standart bir voltaj seviyesidir ve Avrupa, Asya ve Afrika ve Güney Afrika'da kullanılmaktadır. Amerika'nın bazı bölgeleri de dahil olmak üzere dünyanın çeşitli yerlerinde uygulanabilir.

## 6. SONUÇLAR VE ÖNERİLER

Bu sonuç bölümü, 100 kW'lık şebekeye bağlı bir PV sistemi için tasarlanmış önerilen stack LSTM tabanlı MPPT denetleyicisi ile ilgili son açıklamaları ve gelecekteki potansiyel gelişmeleri özetlemektedir.

### 6.1. Sonuçlar

Bu tez çalışmasında, Maksimum Güç Noktası için derin öğrenme (DL) tabanlı Uzun Kısa Süreli Bellek (LSTM) ağı kullanan 100 kW'lık çift aşamalı şebekeye bağlı fotovoltaik (PV) cihaz izleme (MPPT) kontrol sistemi sunulmuştur. Simülasyon Simulink MATLAB 2023'te gerçekleştirildi. Sistem Önerilen sistem iki ana aşamadan oluşmaktadır: ilk aşama 100 kW'lık bir PV dizisi, voltajı 250-280'den 800 V'a çıkarmak için bir takviye dönüştürücü, DC'nin mevcut değerini geri kazanmak için önerilen LSTM tabanlı MPPT kontrolörü G ve T'dir. İkinci aşama, DC'den AC'ye dönüştürme için 3 fazlı Nötr Nokta Kelepçeli (NPC) invertör, harmonik azaltma için bir LCL filtresi ve şebeke aktif güç aktarımı için entegrasyon kontrolleridir. Sistemde, LSTM ağı, dalgalanma koşulları altında PV dizisinin maksimum güç noktası voltajını sürekli olarak tahmin etmek ve izlemek için 1 milyon örnekten oluşan kapsamlı bir veri kümesi üzerinde eğitilmiştir. Önerilen modelin performansı daha sonra MSE, RMSE, MAE, validasyon kaybı ve R-kare kullanılarak değerlendirildi. Her bölümün ayrıntılı katkısı aşağıdaki paragraflarda açıklanmıştır.

İlk aşamada, önerilen sistem, yenilenebilir enerji sağlayan 100 kW TS-SPR-315 PV dizisine dayanmaktadır. PV dizisi, modül başına 96 hücreden, dizi başına 5 seri bağlı modülden ve toplam 102 kW hesaplanmış güç çıkışı için 65 paralel modülden oluşan bir diziden oluşur. Dizinin maksimum gücü  $P_{pv} = P_{max} * N_p * N_s$  denklemi kullanılarak hesaplanır; burada  $P_{max}$  modül başına en yüksek güçtür,  $N_p$  paralel modüllerin sayısıdır ve  $N_s$  seri modüllerin sayısıdır. Bu sistemdeki değerler için  $P_{pv}$ ,  $315 * 65 * 5 = 102\text{-kW}$ 'a eşittir, ancak ölçülen güç 99.86kW'dır (yaklaşık 100 kW'dır). MATLAB/Simulink'te simüle edilen model, güneş dizisi I-V ve P-V eğrilerini temsil etmek için yaygın olarak kullanılan tek diyot modelini kullanır. Tek diyot modeli ve sistem boyutlandırması, bu şebekeye bağlı PV sistemi için yenilenebilir enerji üretim temeli olarak hizmet veren doğru bir 100 kW PV dizisi kaynağı oluşturur.

PV sisteminin ilk aşamasının ikinci önemli bileşeni, ters çevirmeden önce hayati voltaj yükseltme işlemini gerçekleştiren DC-DC yükseltme dönüştürücüsüdür. Bu çalışmada, takviye dönüştürücü, güneş panelinden değişken 250-280V girişi alır ve sabit bir 800V DC bağlantı voltajına yükseltir. Bu 800V çıkış, hem bir sonraki NPC invertör aşamasının girişini hem de DC bağlantısının kendisini oluşturur. Buna göre, takviye konvertörü, sistemin maksimum üretim koşulları (PV dizisinden 250V giriş ve 800V çıkış) göz önünde bulundurularak tasarlanmıştır. Takviye dönüştürücünün görev döngüsünü modüle ederek, 800V'luk hedef DC bağlantı voltajı dalgalanan girişten korunabilir. Bu görev döngüsü kontrolü, hem diziyi optimum voltajda çalıştırarak maksimum güce ulaşan hem de DC bağlantı barasını düzenleyen önerilen LSTM tabanlı MPPT kontrolörü tarafından gerçekleştirilir. Böylece, takviye dönüştürücü, PV dizisi çıkışını ters çevirme ve şebeke bağlantısı için gereken DC bağlantı voltajına dönüştürür.

100kW PV sisteminin ilk aşamasının son unsuru, değişen radyasyon (G) ve sıcaklık (T) altında solar PV dizisinden maksimum güç elde etmek için hayati önem taşıyan Maksimum Güç Noktası İzleme (MPPT) kontrolörüdür. P&O ve IC gibi geleneksel teknikler basitlik sunar, ancak hızlı değişen koşullar sırasında izleme hızından yoksundur. FLC, PSO ve GA gibi hesaplama zekâ yöntemleri uyarlanabilirliği artırır, ancak uygulamada karmaşıklığa sahiptir ve geçmiş verilerden öğrenme yeteneğinden yoksundur. ANN'lar gibi makine öğrenimi yöntemleri doğruluk sağlar, ancak büyük veri kümelerinde performans düşer. RNN mimarileri, geri bildirim kullanarak doğruluğu modeller, ancak eğitim sırasında gradyanların kaybolması sorunuyla karşı karşıyadır. Önerilen çalışma, dahili olarak kapalı hücre durumu akışları aracılığıyla RNN gradyan sorunlarını hafifleten yenilikçi bir derin LSTM ağı uygulamaktadır. LSTM'nin bellek özellikleri, G, T girişleri ve PV dizisi MPP voltajı ( $V_{mp}$ ) arasındaki karmaşık doğrusal olmayan eşlemeyi doğru bir şekilde öğrenmesini sağlar. LSTM MPPT, 1 milyon örnekten oluşan kapsamlı bir veri kümesi üzerinde eğitilmiştir. Sonuçlar, modelleme doğruluğu ve güç toplama performansı açısından geleneksel P&O ve İleri Beslemeli Derin Sinir Ağı (FFDNN) MPPT ile karşılaştırıldı. Eğitim metodolojisi, model değerlendirmesi ve test sonuçları bir sonraki paragrafta sunulmuştur.

Sağlam bir veri işlem hattı ve modelleme yaklaşımı, derin öğrenme MPPT çözümleri için kritik öneme sahiptir. İlk olarak, çalışma aralıkları boyunca kaydedilen ışınlam, sıcaklık ve karşılık gelen maksimum güç noktası voltaj değerlerini içeren 1 milyon örnekten oluşan kapsamlı bir veri seti derlenir. Bu ham veriler daha sonra kullanılmadan önce gürültü filtreleme ve z-skoru normalleştirme gibi ön işleme adımlarından geçirilir.

Normalleştirilmiş veriler daha sonra histogramlar, çubuk grafikler ve korelasyon kullanılarak görselleştirilir. Keşifsel görselleştirme analizi, sinir ağı tasarımını bilgilendirmek için kullanılır. Hem LSTM hem de karşılaştırmalı ileri beslemeli DNN MPPT denetleyicileri, Adam optimizasyon yöntemi, ışınlım ve sıcaklık giriş parametreleri, MPP voltajı olarak hedef çıkış ve sırasıyla 64 ve 32 birimlik iki gizli katmandan oluşan bir topoloji dahil olmak üzere temel hiperparametreleri paylaşır. Hazırlanan verilerin %80'i model parametrelerini eğitmek için kullanılırken, %20'si yalnızca görünmeyen veriler üzerindeki performansı ve genellenebilirliği değerlendirmek için tutuldu. Değerlendirme, Ortalama Kare Hata (MSE), Ortalama Kare Hata Kökü (RMSE), Ortalama Mutlak Hata (MAE) ve belirleme katsayısı (R-kare) gibi standart istatistiksel ölçümlerle ölçülür. Veri toplama, ön işleme, modelleme ve değerlendirmeden oluşan bu titiz işlem hattı, optimum derin öğrenme destekli MPPT için temel sağlar.

Karşılaştırmalı ileri beslemeli Derin Sinir Ağı (DNN) MPPT denetleyicisi, 0.18561 MSE, 0.43083 RMSE, 0.33843 MAE, 0.1'den düşük kayıp fonksiyonu değeri ve 0.80438 R-kare (R<sup>2</sup>) belirleme katsayısı performans kriterlerine ulaştı. Buna karşılık, önerilen LSTM MPPT kontrolörü, 0.0023295 MSE, 0.048265 RMSE, 0.033978 MAE, 0.05'ten düşük kayıp değeri ve 0.99768 R<sup>2</sup> katsayısı gibi üstün değerlendirme kriterlerine ulaşmıştır. DNN'nin tüm kriterlerdeki puanlarını önemli ölçüde aşan LSTM, PV koşullarından maksimum güç noktası voltajlarına kadar doğru eşlemeleri öğrenmedeki olağanüstü yeterliliğini deneysel olarak doğrulamıştır. 80 kattan fazla MSE azaltımı, 9 kat daha düşük RMSE, yaklaşık 10 kat MAE iyileştirmesi ve model uyum ölçüsünde iki kattan fazla artış LSTM'ler, DNN mimarisine göre güneş enerjisi hasadı yeteneklerini önemli ölçüde iyileştirdi.

Önerilen LSTM MPPT kontrolörü hem eğitim hem de test performansında DNN'den daha iyi performans gösterdiğinden, bu modeller 100kW'lık bir PV sisteminin Simulink simülasyonuna aktarıldı ve idealden aşırı ışınlım ve sıcaklık koşullarına kadar dokuz çalışma senaryosu altında standart P&O yaklaşımıyla karşılaştırıldı. P&O veriye dayalı bir tasarım gerektirmese de MPPT kodu doğrudan girişlerden (PV dizisinden voltaj ve akım) M-Dosya kodlamasında uygulanmıştır ve salınımlı çıkışı, maksimum güç noktasını hızlı bir şekilde izlemek için öğrenilmiş eşlemeleri kullanan LSTM ve DNN'ye kıyasla daha düşük ortalama güç sağlar. LSTM'nin yinelemeli mimarisi ve belleği, gelişmiş örüntü tanıma ve daha hızlı adaptasyon sağlayarak 98,7 kW'lık bir güç çıkışı sağlar ve DNN'nin 96,32 kW ve P&O'nun 94,05 kW'lık performansını geride bırakır. LSTM MPPT, veriye dayalı optimizasyondan dinamik simülasyon testine kadar çeşitli

tasarım aşamalarında üstünlüğünü kanıtlamıştır ve uçtan uca kararlı çalışmayı doğrulamak ve gerçek dünya sistemlerinde derin öğrenme tabanlı maksimum güç hasadının fizibilitesini belirlemek için düşüş (droop) invertör kontrolörleri ile entegre edilmiştir.

Önerilen LSTM MPPT, Maksimum Güç Noktasını (MPP) izlemeye dikkate değer bir performans sergiledi. Sonuç olarak, LSTM kontrolörü kullanılarak 100 kW'lık çift aşamalı şebekeye bağlı bir PV sistemi üzerinde simülasyonlar gerçekleştirildi. DC-AC dönüşümü için 3 seviyeli bir Nötr Nokta Kenetlemeli (NPC) invertör kullanıldı. Bu invertör 800V DC bağlantısını üç seviyeye ayırır: +400V, 0 ve -400V. 144A'lık 3 fazlı akım çıkışı ile şebeke tarafında 100 kW'lık güç aktarımı,  $P = 3 \times V_{rms} \times I_{rms} \times \cos(\theta)$  formülü kullanılarak elde edilir  $\times I_{rms} \times \cos(\theta)$ , burada  $V_{rms}$  invertör çıkış voltajıdır,  $I_{rms}$  kök ortalama kare akımdır ve  $\theta$  güç faktörünü temsil eder. ABB PVS-100/101 gibi piyasada bulunan 100 kW dizi invertörler, gerekli 144A/400V değerlerini kolayca sağlayabilir. NPC invertörü, DC bağlantısını harici bir voltaj kontrol döngüsü ve bir dahili akım döngüsü aracılığıyla düzenleyerek kararlılığı korur. Şebeke gerilimi fazı ile senkronize olan invertör, herhangi bir reaktif güç akışı olmadan birim güç faktöründe tam aktif güç enjeksiyonu sağlar.

Şebekeye bağlı PV sistemlerinin kararlılığı, aktif güç aktarımını optimize etmek, verimliliği ve güvenilirliği artırmak için DC bara voltajının, frekansının ve güç paylaşım stratejilerinin etkili bir şekilde düzenlenmesine dayanır. NPC invertörün simüle edilmiş çıkış dalga biçimleri, voltaj %2'nin altında ve akım %3'ün altında olmak üzere düşük toplam harmonik bozulma (THD) sergiler ve katı şebeke yönetmelikleri gereksinimlerini karşılar. Türkiye'de TEİAŞ, Pakistan'da NEPRA gibi otoriteler tarafından belirlenen standartlara ve uluslararası şebeke kodlarına uygunluk, THD seviyeleri %5'in altında olacak şekilde sorunsuz şebeke senkronizasyonu sağlar. Bu sonuçlar, inverterin şebeke ara bağlantısı için uygun yüksek kaliteli sinüzoidal voltajlar ve akımlar üretme kabiliyetini doğrulayarak kararlı ve güvenilir şebeke çalışmasını teşvik eder.

LCL filtresi, gerekli harmonik zayıflamayı sağlarken minimum reaktif güç için kısıtlı bir optimizasyon stratejisi kullanılarak tasarlanmıştır. Bileşen boyutlandırma, dönüştürücü tarafı indüktör dalgalanma limitlerini, şebeke tarafı yüksek frekans zayıflamasını dikkate alır. Nihai değerler-  $L_1=3\text{mH}$ ,  $L_2=2\text{mH}$ ,  $C=15\mu\text{F}$ 'dir. Bu değerler, tüm reaktif gücün dahili olarak çekildiği şebeke koduna uygun bir filtre çıkışı sağlar. NPC invertör ile birlikte LCL filtresi, fotovoltaik dizinin 97kW aktif gücünün %100'ünün tehlikeli harmonikler veya reaktif kaynak tüketimi olmadan şebekeye aktarılmasını

sağlar. Bu, optimize edilmiş filtrenin ve hassas kontrolün şebeke korumasına katkıda bulunduğunu ve yenilenebilir enerjinin entegrasyonunu sağladığını kanıtlıyor.

Sonuç olarak, bu çalışma, LSTM derin öğrenme ağı tabanlı maksimum güç noktası izleme özelliğine sahip, şebekeye entegre 100 kW'lık bir solar PV sistemini göstermektedir. LSTM, geleneksel teknikleri geride bırakır ve mevcut PV kaynağından 98,4 kW'a ulaşır. 800V DC bağlantısı daha sonra harmonikleri katı %5 THD sınırları içinde azaltmak için LCL filtrelemeli çok seviyeli bir invertör aracılığıyla 400V/144A'ya dönüştürülür. Önerilen yaklaşım, 98,4 kW güneş enerjisinin şebekeye transferini kolaylaştırdı ve uluslararası standartları doğrulayan simülasyonlarla doğrulandı. %95-99'luk verimli bir LSTM çıkarımı ile örneklenen gelişmiş makine öğrenimi çözümleri, temiz enerji sistemleri için etkili yenilenebilir enerji kullanımının ilerlemesini kanıtlıyor.

## 6.2. Öneriler

Önerilen 100kW dağıtık sistem, eğitim veri hacmi, yüksek öğrenme için model karmaşıklığı ve bileşen ölçeklendirmesi artırılarak daha büyük akıllı şebeke ağlarına genişletilebilir. Işınım, sıcaklık ve gerilim veri kümelerinin daha geniş operasyonel ortamlarda genişletilmesi, farklı koşullarda doğru çok değişkenli haritalama sağlar. Daha yüksek boyutlu uzay dönüşümlerine sahip daha derin ağ topolojileri, karmaşık şebeke davranışlarını daha iyi yakalar. Seri-paralel güç elektroniği konfigürasyonları da geniş coğrafi bölgelerde dağıtımı kolaylaştırır.

3 seviyeli bir NPC inverter mevcut sisteme yeterince hizmet verecek olsa da daha büyük tesisler filtreleme gereksinimlerini ve kayıpları en aza indirmek için daha düzgün, neredeyse mükemmel sinüzoidal çıkışlar sentezlemek üzere kademeli çok seviyeli inverterler veya modüler çok seviyeli dönüştürücüler kullanabilir. Ek voltaj seviyeleri, yüksek kapasiteli yenilenebilir entegrasyonu için güç kalitesini artırır. Dönüştürücü modülerleştirilmesi ayrıca birkaç kilovattan yüzlerce megavata kadar yapılandırılabilir tasarımlara olanak tanır.

Sağlam istatistiksel ölçümler ve kontrolsüz dinamikler üzerinde testler kullanılarak simülasyonda kapsamlı bir şekilde yürütülen model eğitimi ve değerlendirmesiyle, maliyetli prototip oluşturmadan önce gerçek dünyadaki dağıtımın fizibilitesi kanıtlanmıştır. Yerleşik sinir ağı MPPT denetleyicilerine beslenen ADC sensörü veri toplama ile doğrudan simüle edilmiş prototiplerin üzerine pratik uygulama oluşturulabilir. Sorunsuz fiziksel entegrasyon, eşzamanlı veri akışı ve model çıkarımı için

doğru kalibrasyona, bant genişliğinin algılanmasına, analog filtre tasarımlarına ve yeterli veri yolu hızlarına dayanır. Simülasyonun yazılım ve donanım uygulamalarına metodik geçişi, yenilenebilir enerjinin ilerlemesini sağlar.



## KAYNAKLAR

- Ab-Belkhair, A., Rahebi, J., & Abdulhamed Mohamed Nureddin, A. (2020). A study of deep neural network controller-based power quality improvement of hybrid PV/Wind systems by using smart inverter. *International Journal of Photoenergy*, 2020. <https://doi.org/10.1155/2020/8891469>
- Abdelsalam, A. A., Esmaeel, M. A., & Zaid, S. A. (2021). Two-level inverter and three-level neutral point diode clamped inverter for traction applications: A comparative analysis study. *International Journal of Power Electronics and Drive Systems*, 12(3). <https://doi.org/10.11591/ijpeds.v12.i3.pp1609-1619>
- Abo-Elyours, F. K., & Abdelaziz, A. Y. (2018). Optimal PI microcontroller-based realization for technical trends of single-stage single-phase grid-tied PV. *Engineering Science and Technology, an International Journal*, 21(5). <https://doi.org/10.1016/j.jestch.2018.07.007>
- Adamantiades, A., & Kessides, I. (2009). Nuclear power for sustainable development: Current status and future prospects. *Energy Policy*, 37(12), 5149–5166. <https://doi.org/10.1016/j.enpol.2009.07.052>
- Aggarwal, A., Kunta, S., & Verma, P. K. (2010). A proposed communications infrastructure for the smart grid. *Innovative Smart Grid Technologies Conference, ISGT 2010*. <https://doi.org/10.1109/ISGT.2010.5434764>
- Akkaya, R., Kulaksiz, A. A., & Aydoğdu, Ö. (2007). DSP implementation of a PV system with GA-MLP-NN based MPPT controller supplying BLDC motor drive. *Energy Conversion and Management*, 48(1). <https://doi.org/10.1016/j.enconman.2006.04.022>
- Akundi, A., Euresti, D., Luna, S., Ankobiah, W., Lopes, A., & Edinbarough, I. (2022). State of Industry 5.0—Analysis and Identification of Current Research Trends. *Applied System Innovation*, 5(1). <https://doi.org/10.3390/asi5010027>
- Al-muzaini, H. A., Al-yahya, T. N., & Benhidour, H. (2018). Automatic Arabic image captioning using RNN-LSTM-based language model and CNN. *International Journal of Advanced Computer Science and Applications*, 9(6). <https://doi.org/10.14569/IJACSA.2018.090610>
- Alhejji, A., & Mosaad, M. I. (2021). Performance enhancement of grid-connected PV systems using adaptive reference PI controller. *Ain Shams Engineering Journal*, 12(1), 541–554. <https://doi.org/10.1016/j.asej.2020.08.006>
- Ali, Z., Christofides, N., Hadjidemetriou, L., & Kyriakides, E. (2018). Design of an advanced PLL for accurate phase angle extraction under grid voltage HIHs and DC offset. *IET Power Electronics*, 11(6), 995–1008. <https://doi.org/10.1049/iet-pel.2017.0424>
- Allahabadi, S., Iman-Eini, H., & Farhangi, S. (2022). Fast Artificial Neural Network Based Method for Estimation of the Global Maximum Power Point in Photovoltaic Systems. *IEEE Transactions on Industrial Electronics*, 69(6), 5879–5888. <https://doi.org/10.1109/TIE.2021.3094463>
- Alsharef, A., Sonia, Kumar, K., & Iwendi, C. (2022). Time Series Data Modeling Using Advanced Machine Learning and AutoML. *Sustainability (Switzerland)*, 14(22). <https://doi.org/10.3390/su142215292>
- Altin, N., Ozdemir, S., Komurcugil, H., Sefa, I., & Biricik, S. (2018). Two-stage grid-connected inverter for PV systems. *Proceedings - 2018 IEEE 12th International Conference on Compatibility, Power Electronics and Power Engineering, CPE-POWERENG 2018*, 1–6. <https://doi.org/10.1109/CPE.2018.8372540>
- Anani, N., & Ibrahim, H. (2020). Adjusting the single-diode model parameters of a



- photovoltaic module with irradiance and temperature. *Energies*, 13(12). <https://doi.org/10.3390/en13123226>
- Ansari, M. F., Chatterji, S., & Iqbal, A. (2013). Fuzzy logic-based MPPT controllers for three-phase grid-connected inverters. *International Journal of Sustainable Energy*, 32(3), 186–195. <https://doi.org/10.1080/14786451.2011.605948>
- Anwer, A. M. O., Omar, F. A., & Kulaksiz, A. A. (2020). Design of a Fuzzy Logic-based MPPT Controller for a PV System Employing Sensorless Control of MRAS-based PMSM. *International Journal of Control, Automation and Systems*, 18(11). <https://doi.org/10.1007/s12555-019-0512-8>
- Apeh, O. O., Meyer, E. L., & Overen, O. K. (2022). Contributions of Solar Photovoltaic Systems to Environmental and Socioeconomic Aspects of National Development—A Review. In *Energies* (Vol. 15, Issue 16). MDPI. <https://doi.org/10.3390/en15165963>
- Asesh, A. (2022). Normalization and Bias in Time Series Data. *Lecture Notes in Networks and Systems*, 440 LNNS. [https://doi.org/10.1007/978-3-031-11432-8\\_8](https://doi.org/10.1007/978-3-031-11432-8_8)
- Attanasio, R., Cacciato, M., Gennaro, F., Scarcella, G., & Doria, V. A. (2008). Review on Single-phase PV Inverters for Grid-connected Applications. *4th IASME/WSEAS International Conference on ENERGY, ENVIRONMENT, ECOSYSTEMS and SUSTAINABLE DEVELOPMENT (EEESD'08)*.
- Avila, L., De Paula, M., Trimboli, M., & Carlucho, I. (2020). Deep reinforcement learning approach for MPPT control of partially shaded PV systems in Smart Grids. *Applied Soft Computing*, 97, 106711. <https://doi.org/10.1016/j.asoc.2020.106711>
- Ayop, R., & Tan, C. W. (2018). Design of boost converter based on maximum power point resistance for photovoltaic applications. *Solar Energy*, 160. <https://doi.org/10.1016/j.solener.2017.12.016>
- Bahari, M. I., Tarassodi, P., Naeini, Y. M., Khalilabad, A. K., & Shirazi, P. (2016). Modeling and simulation of hill climbing MPPT algorithm for photovoltaic application. *2016 International Symposium on Power Electronics, Electrical Drives, Automation and Motion, SPEEDAM 2016*, 1041–1044. <https://doi.org/10.1109/SPEEDAM.2016.7525990>
- Bektas, E., & Karaca, H. (2019). GA based selective harmonic elimination for multilevel inverter with reduced number of switches: An experimental study. *Elektronika Ir Elektrotechnika*, 25(3). <https://doi.org/10.5755/j01.eie.25.3.23670>
- Bektaş, Y., & Karaca, H. (2022). Red deer algorithm based selective harmonic elimination for renewable energy application with unequal DC sources. *Energy Reports*, 8. <https://doi.org/10.1016/j.egyr.2022.05.209>
- Beniysa, M., El Idrissi, A. E. J., Bouajaj, A., & Britel, M. R. (2019). An iterative approach for modeling a photovoltaic module using the complete single-diode model. *2019 International Conference on Intelligent Systems and Advanced Computing Sciences (ISACS)*, 1–7.
- Bhanja, S., & Das, A. (2018). *Impact of Data Normalization on Deep Neural Network for Time Series Forecasting*. 5–10. <http://arxiv.org/abs/1812.05519>
- Bhavani, M., Vijaybhaskar Reddy, K., Mahesh, K., & Saravanan, S. (2023). Impact of variation of solar irradiance and temperature on the inverter output for grid connected photo voltaic (PV) system at different climate conditions. *Materials Today: Proceedings*, 80. <https://doi.org/10.1016/j.matpr.2021.06.120>
- Blaabjerg, F., Teodorescu, R., Liserre, M., & Timbus, A. V. (2006). Overview of control and grid synchronization for distributed power generation systems. *IEEE Transactions on Industrial Electronics*, 53(5), 1398–1409. <https://doi.org/10.1109/TIE.2006.881997>

- Bollipo, R. B., Mikkili, S., & Bonthagorla, P. K. (2021). Hybrid, optimal, intelligent and classical PV MPPT techniques: A review. In *CSEE Journal of Power and Energy Systems* (Vol. 7, Issue 1). <https://doi.org/10.17775/CSEEJPES.2019.02720>
- Bouaouaou, H., Lalili, D., & Boudjerda, N. (2022). Model predictive control and ANN-based MPPT for a multi-level grid-connected photovoltaic inverter. *Electrical Engineering*, 104(3), 1229–1246. <https://doi.org/10.1007/s00202-021-01355-w>
- Bouktif, S., Fiaz, A., Ouni, A., & Serhani, M. A. (2020). Multi-sequence LSTM-RNN deep learning and metaheuristics for electric load forecasting. *Energies*, 13(2). <https://doi.org/10.3390/en13020391>
- Calais, M., Agelidis, V. G., & Meinhardt, M. (1999). Multilevel converters for single-phase grid connected photovoltaic systems: An overview. *Solar Energy*, 66(5). [https://doi.org/10.1016/S0038-092X\(99\)00035-3](https://doi.org/10.1016/S0038-092X(99)00035-3)
- Chang, E. C., Cheng, H. L., Chang, C. H., Wu, R. C., Cheng, C. A., Xiao, Z. K., Lu, W. J., & Wei, Z. Y. (2022). Robust Optimal Control Design for Performance Enhancement of PWM Voltage Source Inverter. *Micromachines*, 13(3). <https://doi.org/10.3390/mi13030435>
- Chatterjee, A. S. (2023). A Bus Clamping PWM-Based Improved Control of Grid Tied PV Inverter with LCL Filter Under Varying Grid Frequency Condition. *IETE Journal of Research*, 69(2). <https://doi.org/10.1080/03772063.2020.1844067>
- Chen, C. S., Lin, C. J., & Lai, C. C. (2022). Non-Contact Service Robot Development in Fast-Food Restaurants. *IEEE Access*, 10, 31466–31479. <https://doi.org/10.1109/ACCESS.2022.3155661>
- Chen, Daolian, Jiang, J., Qiu, Y., Zhang, J., & Huang, F. (2017). Single-Stage Three-Phase Current-Source Photovoltaic Grid-Connected Inverter High Voltage Transmission Ratio. *IEEE Transactions on Power Electronics*, 32(10). <https://doi.org/10.1109/TPEL.2016.2622722>
- Chen, Dewang, Lu, Y., & Hsu, C. Y. (2022). Measurement Invariance Investigation for Performance of Deep Learning Architectures. *IEEE Access*, 10. <https://doi.org/10.1109/ACCESS.2022.3192468>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7. <https://doi.org/10.7717/PEERJ-CS.623>
- Choi, J. E., & Shin, D. W. (2021). A self-normalization break test for correlation matrix. *Statistical Papers*, 62(5). <https://doi.org/10.1007/s00362-020-01188-y>
- Chollet, F. (n.d.). *Deep Learning with Python* (Second Edi). MANNING SHELTER ISLAND. <https://sourestdeds.github.io/pdf/Deep Learning with Python.pdf>
- Chouhan, P., Chourey, A., & Yadav, B. (2021). Performance Analysis of Grid tied Three Phase Single Stage and Dual Stage PV system; A Review Paper. *Journal for Research*, 07. [www.journal4research.org](http://www.journal4research.org)
- Cocianu, C. L., Uscatu, C. R., & Avramescu, M. (2022). Improvement of LSTM-Based Forecasting with NARX Model through Use of an Evolutionary Algorithm. *Electronics (Switzerland)*, 11(18). <https://doi.org/10.3390/electronics11182935>
- Das, P. (2016). Maximum Power Tracking Based Open Circuit Voltage Method for PV System. *Energy Procedia*, 90(December 2015), 2–13. <https://doi.org/10.1016/j.egypro.2016.11.165>
- Dharma Raj, T., C, K., Subramaniam, G., Dharma Raj, T., & Jasper, J. (2023). A novel ROA optimized Bi-LSTM based MPPT controller for grid connected hybrid solar-wind system. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 42(2), 378–401.

- <https://doi.org/10.1108/COMPEL-11-2021-0453>
- Duan, J., Zhang, P. F., Qiu, R., & Huang, Z. (2022). Long short-term enhanced memory for sequential recommendation. *World Wide Web*. <https://doi.org/10.1007/s11280-022-01056-9>
- Edenhofer, O., Pichs-Madruga, R., Sokona, Y., Seyboth, K., Kadner, S., Zwickel, T., Eickemeier, P., Hansen, G., Schlömer, S., Stechow, C. von, & Matschoss, P. (2011). Renewable Energy Sources and Climate Change Mitigation: Special Report of the Intergovernmental Panel on Climate Change (IPCC). *Cambridge University Press, Cambridge, UK and New York, NY, USA*.
- Edenhofer, O., Pichs Madruga, R., Sokona, Y., United Nations Environment Programme., World Meteorological Organization., Intergovernmental Panel on Climate Change. Working Group III., & Potsdam-Institut für Klimafolgenforschung. (2012). *Renewable energy sources and climate change mitigation : special report of the Intergovernmental Panel on Climate Change*. Cambridge University Press.
- El-Khozondar, H. J., El-Khozondar, R. J., Matter, K., & Suntio, T. (2016). A review study of photovoltaic array maximum power tracking algorithms. *Renewables: Wind, Water, and Solar*, 3(1), 3. <https://doi.org/10.1186/s40807-016-0022-8>
- El Mezdi, K., El Magri, A., Watil, A., El Myasse, I., Bahatti, L., Lajouad, R., & Ouabi, H. (2023). Nonlinear control design and stability analysis of hybrid grid-connected photovoltaic-Battery energy storage system with ANN-MPPT method. *Journal of Energy Storage*, 72(PE), 108747. <https://doi.org/10.1016/j.est.2023.108747>
- Ergen, T., & Kozat, S. S. (2018). Online Training of LSTM Networks in Distributed Systems for Variable Length Data Sequences. *IEEE Transactions on Neural Networks and Learning Systems*, 29(10). <https://doi.org/10.1109/TNNLS.2017.2770179>
- Esram, T., & Chapman, P. L. (2007). Comparison of photovoltaic array maximum power point tracking techniques. *IEEE Transactions on Energy Conversion*, 22(2), 439–449. <https://doi.org/10.1109/TEC.2006.874230>
- Farzad, A., Mashayekhi, H., & Hassanpour, H. (2019). A comparative performance analysis of different activation functions in LSTM networks for classification. *Neural Computing and Applications*, 31(7). <https://doi.org/10.1007/s00521-017-3210-6>
- Femia, N., Petrone, G., Spagnuolo, G., & Vitelli, M. (2009). A technique for improving P&O MPPT performances of double-stage grid-connected photovoltaic systems. *IEEE Transactions on Industrial Electronics*, 56(11), 4473–4482. <https://doi.org/10.1109/TIE.2009.2029589>
- Fine, T. L. (2005). Fundamentals of Artificial Neural Networks [Book Reviews]. *IEEE Transactions on Information Theory*, 42(4). <https://doi.org/10.1109/tit.1996.508868>
- Forootan, M. M., Larki, I., Zahedi, R., & Ahmadi, A. (2022). Machine Learning and Deep Learning in Energy Systems: A Review. In *Sustainability (Switzerland)* (Vol. 14, Issue 8). MDPI. <https://doi.org/10.3390/su14084832>
- Gawhade, P., & Ojha, A. (2021). Recent advances in synchronization techniques for grid-tied PV system: A review. In *Energy Reports* (Vol. 7). <https://doi.org/10.1016/j.egyr.2021.09.006>
- Gers, F. A., Uergen Schmidhuber, J. ., & Cummins, F. (n.d.). *Learning to Forget: Continual Prediction with LSTM*.
- Gholamy, A., Kreinovich, V., & Kosheleva, O. (2018). Why 70/30 Or 80/20 Relation Between Training And Testing Sets : A Pedagogical Explanation. In *Departmental Technical Reports (CS)* (Vol. 1209).
- GHOSHAL, A. N. I. R. B. A. N., & JOHN, V. I. N. O. D. (2015). A controller design

- method for 3 phase 4 wire grid connected VSI with LCL filter. *Sadhana - Academy Proceedings in Engineering Sciences*, 40(5). <https://doi.org/10.1007/s12046-015-0393-3>
- Gorai, S., Sattianadan, D., Shanmugasundaram, V., Vidyasagar, S., Prudhvi Kumar, G. R., & Sudhakaran, M. (2020). Investigation of voltage regulation in grid connected PV system. *Indonesian Journal of Electrical Engineering and Computer Science*, 19(3). <https://doi.org/10.11591/ijeecs.v19.i3.pp1131-1139>
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77. <https://doi.org/10.1016/j.patcog.2017.10.013>
- Gullu, S., Djaho, A. C., Rezaii, R., Elrais, M. T., Safayatullah, M., Mensah, A., & Batarseh, I. (2022). Advanced Systems Integration of 540 KVA Inverter and 1.86 MWh Battery Energy Storage System for Microgrid Application: A Case Study. *2022 13th International Renewable Energy Congress, IREC 2022, Irec*, 1–5. <https://doi.org/10.1109/IREC56325.2022.10002117>
- Haas, J. C., Switanek, M., & Birk, S. (2018). Analysis of hydrological data with correlation matrices: technical implementation and possible applications. *Environmental Earth Sciences*, 77(8). <https://doi.org/10.1007/s12665-018-7469-4>
- Hadji, S., Gaubert, J. P., & Krim, F. (2018). Real-time Genetic Algorithms-based MPPT: Study and comparison (theoretical an experimental) with conventional methods. *Energies*, 11(2). <https://doi.org/10.3390/en11020459>
- Hagan, M. T., Demuth, H. B., & De Jesús, O. (2002). An introduction to the use of neural networks in control systems. *International Journal of Robust and Nonlinear Control*, 12(11). <https://doi.org/10.1002/rnc.727>
- Haifa Zahrah, H., Sa'adah, S., & Rismala, R. (2021). The Foreign Exchange Rate Prediction Using Long-Short Term Memory. *International Journal on Information and Communication Technology (IJoICT)*, 6(2). <https://doi.org/10.21108/ijoict.2020.62.538>
- Hassan, M. K., Alqurashi, I. M., Salama, A. E., & Mohamed, A. F. (2022). Investigation the performance of PV solar cells in extremely hot environments. *Journal of Umm Al-Qura University for Engineering and Architecture*. <https://doi.org/10.1007/s43995-022-00005-x>
- Heaton, J. (2012). *Introduction to the Math of Neural Networks*. <http://www.heatonresearch.com/book/introduction-neural-network-math.html>
- Hossain, M. S., & Mahmood, H. (2020). Short-term photovoltaic power forecasting using an LSTM neural network and synthetic weather forecast. *IEEE Access*, 8. <https://doi.org/10.1109/ACCESS.2020.3024901>
- Huang, T., Shi, X., Sun, Y., & Wang, D. (2013). Three-phase photovoltaic grid-connected inverter based on feedforward decoupling control. *ICMREE 2013 - Proceedings: 2013 International Conference on Materials for Renewable Energy and Environment*, 2, 476–480. <https://doi.org/10.1109/ICMREE.2013.6893714>
- Huo, D., & Meckl, P. (2022). Power Management of a Plug-in Hybrid Electric Vehicle Using Neural Networks with Comparison to Other Approaches. *Energies*, 15(15). <https://doi.org/10.3390/en15155735>
- Husein, M., & Chung, I. Y. (2019). Day-ahead solar irradiance forecasting for microgrids using a long short-term memory recurrent neural network: A deep learning approach. *Energies*, 12(10). <https://doi.org/10.3390/en12101856>
- Huynh, D. C., & Dunnigan, M. W. (2016). Development and comparison of an improved incremental conductance algorithm for tracking the MPP of a solar PV panel. *IEEE Transactions on Sustainable Energy*, 7(4), 1421–1429.

- <https://doi.org/10.1109/TSTE.2016.2556678>
- Indrakumari, R., Poongodi, T., & Singh, K. (2021). Introduction to Deep Learning. In *EAI/Springer Innovations in Communication and Computing*. [https://doi.org/10.1007/978-3-030-66519-7\\_1](https://doi.org/10.1007/978-3-030-66519-7_1)
- Inglis, A., Parnell, A., & Hurley, C. B. (2022). Visualizing Variable Importance and Variable Interaction Effects in Machine Learning Models. *Journal of Computational and Graphical Statistics*, 31(3). <https://doi.org/10.1080/10618600.2021.2007935>
- Ishaque, K., Salam, Z., Amjad, M., & Mekhilef, S. (2012). An improved particle swarm optimization (PSO)-based MPPT for PV with reduced steady-state oscillation. *IEEE Transactions on Power Electronics*, 27(8), 3627–3638. <https://doi.org/10.1109/TPEL.2012.2185713>
- Islam, M., Mekhilef, S., & Hasan, M. (2015). Single phase transformerless inverter topologies for grid-tied photovoltaic system: A review. In *Renewable and Sustainable Energy Reviews* (Vol. 45, pp. 69–86). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2015.01.009>
- Ito, S., Murakami, T. N., Comte, P., Liska, P., Grätzel, C., Nazeeruddin, M. K., & Grätzel, M. (2008). Fabrication of thin film dye sensitized solar cells with solar to electric power conversion efficiency over 10%. *Thin Solid Films*, 516(14). <https://doi.org/10.1016/j.tsf.2007.05.090>
- J. Sadhukhan, S. C. and S. B. (2018). *Solar Photovoltaic System Applications: A Guidebook for Off-Grid Electrification*. CRC Press.
- Jagadeesan, G. M., Pitchaimuthu, R., & Sridharan, M. (2022). A Two-stage Single-phase Grid-connected Solar-PV System with Simplified Power Regulation. *Chinese Journal of Electrical Engineering*, 8(1), 81–92. <https://doi.org/10.23919/CJEE.2022.000008>
- Jason, B. (2018). Deep Learning for Time Series Forecasting (Top Reference). *ML*, 1(1), 1–50.
- Javadi, M. A., Hoseinzadeh, S., Ghasemiasl, R., Heyns, P. S., & Chamkha, A. J. (2020). Sensitivity analysis of combined cycle parameters on exergy, economic, and environmental of a power plant. *Journal of Thermal Analysis and Calorimetry*, 139(1), 519–525. <https://doi.org/10.1007/s10973-019-08399-y>
- Jepkoech, J., Mugo, D. M., Kenduiywo, B. K., & Too, E. C. (2021). The Effect of Adaptive Learning Rate on the Accuracy of Neural Networks. *International Journal of Advanced Computer Science and Applications*, 12(8). <https://doi.org/10.14569/IJACSA.2021.0120885>
- Jin, M., Liao, Q., Patil, S., Abdulraheem, A., Al-Shehri, D., & Glatz, G. (2022). Hyperparameter Tuning of Artificial Neural Networks for Well Production Estimation Considering the Uncertainty in Initialized Parameters. *ACS Omega*, 7(28). <https://doi.org/10.1021/acsomega.2c00498>
- John, R., Mohammed, S. S., & Zachariah, R. (2018). Variable step size Perturb and observe MPPT algorithm for standalone solar photovoltaic system. *Proceedings of the 2017 IEEE International Conference on Intelligent Techniques in Control, Optimization and Signal Processing, INCOS 2017, 2018-Febru*, 1–6. <https://doi.org/10.1109/ITCOSP.2017.8303163>
- Kabalci, E., Boyar, A., & Kabalci, Y. (2021). Pulse width modulation and control methods for multilevel inverters. In *Multilevel Inverters: Control Methods and Advanced Power Electronic Applications*. <https://doi.org/10.1016/B978-0-323-90217-5.00009-5>
- Kalbandi, I., Jare, A., Kale, O., Borole, H., & Navsare, S. (2021). Stock Market Prediction Using LSTM. *International Journal of Advanced Research in Science*,

- Communication and Technology*. <https://doi.org/10.48175/ijarsct-877>
- KARABİNAOĞLU, M. S., ÇAKIR, B., BAŞOĞLU, M. E., KAZDALOĞLU, A., & GÜNEROĞLU, A. (2022). Comparison of deep learning and regression-based MPPT algorithms in PV systems. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(6), 2319–2338. <https://doi.org/10.55730/1300-0632.3941>
- Karaca, H., & Bektas, E. (2016). Selective harmonic elimination using genetic algorithm for multilevel inverter with reduced number of power switches. *Engineering Letters*, 24(2).
- Kaundinya, D. P., Balachandra, P., & Ravindranath, N. H. (2009). Grid-connected versus stand-alone energy systems for decentralized power-A review of literature. In *Renewable and Sustainable Energy Reviews* (Vol. 13, Issue 8, pp. 2041–2050). <https://doi.org/10.1016/j.rser.2009.02.002>
- Khan, M. N. H., Forouzes, M., Siwakoti, Y. P., Li, L., Kerekes, T., & Blaabjerg, F. (2020). Transformerless Inverter Topologies for Single-Phase Photovoltaic Systems: A Comparative Review. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 8(1). <https://doi.org/10.1109/JESTPE.2019.2908672>
- Khumaidi, A., Raafi'udin, R., & Solihin, I. P. (2020). Pengujian Algoritma Long Short-Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung. *Jurnal Telematika*, 15(1).
- Kim, I. S. (2007). Robust maximum power point tracker using sliding mode controller for the three-phase grid-connected photovoltaic system. *Solar Energy*, 81(3), 405–414. <https://doi.org/10.1016/j.solener.2006.04.005>
- Kofinas, P., Doltsinis, S., Dounis, A. I., & Vouras, G. A. (2017). A reinforcement learning approach for MPPT control method of photovoltaic sources. *Renewable Energy*, 108, 461–473.
- Korkmaz, D., & Acikgoz, H. (2022). An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network. *Engineering Applications of Artificial Intelligence*, 113. <https://doi.org/10.1016/j.engappai.2022.104959>
- Krishna, B., Bheemraj, T. S., & Karthikeyan, V. (2021). Optimized active power management in solar pv-fed transformerless grid-connected system for rural electrified microgrid. *Journal of Circuits, Systems and Computers*, 30(3). <https://doi.org/10.1142/S0218126621500390>
- Krishnamurthy, K., Padmanaban, S., Blaabjerg, F., Neelakandan, R. B., & Prabhu, K. R. (2019). Power Electronic Converter Configurations Integration with Hybrid Energy Sources—A Comprehensive Review for State-of-the-Art in Research. *Electric Power Components and Systems*, 47(18), 1623–1650. <https://doi.org/10.1080/15325008.2019.1689457>
- Kulaksiz, A. A. (2013). ANFIS-based estimation of PV module equivalent parameters: Application to a stand-alone PV system with MPPT controller. *Turkish Journal of Electrical Engineering and Computer Sciences*, 21(SUPPL. 2). <https://doi.org/10.3906/elk-1201-41>
- Kulaksiz, A. A., & Akkaya, R. (2012a). A genetic algorithm optimized ANN-based MPPT algorithm for a stand-alone PV system with induction motor drive. *Solar Energy*, 86(9). <https://doi.org/10.1016/j.solener.2012.05.006>
- Kulaksiz, A. A., & Akkaya, R. (2012b). Training data optimization for ANNs using genetic algorithms to enhance MPPT efficiency of a stand-alone PV system. *Turkish Journal of Electrical Engineering and Computer Sciences*, 20(2). <https://doi.org/10.3906/elk-1101-1051>
- Kwak, S., & Toliyat, H. A. (2006). A current source inverter with advanced external

- circuit and control method. *IEEE Transactions on Industry Applications*, 42(6). <https://doi.org/10.1109/TIA.2006.882620>
- Liao, L., Li, H., Shang, W., & Ma, L. (2022). An Empirical Study of the Impact of Hyperparameter Tuning and Model Optimization on the Performance Properties of Deep Neural Networks. *ACM Transactions on Software Engineering and Methodology*, 31(3). <https://doi.org/10.1145/3506695>
- Lopez-Santos, O. (2015). Contribution to the DC-AC conversion in photovoltaic systems: Module oriented converters. *Citeseer*, 248. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.633.244&rep=rep1&type=pdf%5Cnhttps://tel.archives-ouvertes.fr/tel-01146805/>
- Los, U. M. D. E. C. D. E. (n.d.). No 主観的健康感を中心とした在宅高齢者における健康関連指標に関する共分散構造分析Title.
- Madouh, J., Ahmed, N. A., & Al-Kandari, A. M. (2012). Advanced power conditioner using sinewave modulated buck-boost converter cascaded polarity changing inverter. *International Journal of Electrical Power and Energy Systems*, 43(1). <https://doi.org/10.1016/j.ijepes.2012.05.002>
- Mahlooji, M. H., Mohammadi, H. R., & Rahimi, M. (2018). A review on modeling and control of grid-connected photovoltaic inverters with LCL filter. In *Renewable and Sustainable Energy Reviews* (Vol. 81, pp. 563–578). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2017.08.002>
- Makkiabadi, M., Hoseinzadeh, S., Taghavirashidizadeh, A., Soleimaninezhad, M., Kamyabi, M., Hajabdollahi, H., Nezhad, M. M., & Piras, G. (2021). Performance evaluation of solar power plants: A review and a case study. In *Processes* (Vol. 9, Issue 12). MDPI. <https://doi.org/10.3390/pr9122253>
- Malakar, S., Goswami, S., Ganguli, B., Chakrabarti, A., Roy, S. Sen, Boopathi, K., & Rangaraj, A. G. (2021). Designing a long short-term network for short-term forecasting of global horizontal irradiance. *SN Applied Sciences*, 3(4), 1–15. <https://doi.org/10.1007/s42452-021-04421-x>
- Merai, M., Naouar, M. W., Slama-Belkhodja, I., & Monmasson, E. (2021). A systematic design methodology for DC-link voltage control of single phase grid-tied PV systems. *Mathematics and Computers in Simulation*, 183, 158–170. <https://doi.org/10.1016/j.matcom.2020.05.007>
- Mertens, K. (n.d.). *Photovoltaics*.
- Mirafzal, B., & Adib, A. (2020). On Grid-Interactive Smart Inverters: Features and Advancements. *IEEE Access*, 8. <https://doi.org/10.1109/ACCESS.2020.3020965>
- Mishra, D. P., Rout, K. K., Mishra, S., Nivas, M., Naidu, R. K. P. R., & Salkuti, S. R. (2023). Power quality enhancement of grid-connected PV system. *International Journal of Power Electronics and Drive Systems*, 14(1). <https://doi.org/10.11591/ijpeds.v14.i1.pp369-377>
- Mohammad, K. A., & Musa, S. M. (2022). Optimization of Solar Energy Using Recurrent Neural Network Controller. *Proceedings - 2022 14th IEEE International Conference on Computational Intelligence and Communication Networks, CICN 2022, 2022-January*. <https://doi.org/10.1109/CICN56167.2022.10041248>
- Mohan, N., Undeland, T. M., & Robbins, W. P. (2003). *Power electronics: converters, applications, and design*. John Wiley & Sons.
- Morales, M., Hélias, A., & Bernard, O. (2019). Optimal integration of microalgae production with photovoltaic panels: Environmental impacts and energy balance. *Biotechnology for Biofuels*, 12(1). <https://doi.org/10.1186/s13068-019-1579-4>
- Mukerjee, A. K., & Thakur, N. (2011). *Photovoltaic Systems: Analysis and Design*. PHI Learning Pvt. Ltd.

- Novitasari, D. C. R., Rohayani, H., Suwanto, Arnita, Rico, Junaidi, R., Setyowati, R. D. N., Pramulya, R., & Setiawan, F. (2020). Weather Parameters Forecasting as Variables for Rainfall Prediction using Adaptive Neuro Fuzzy Inference System (ANFIS) and Support Vector Regression (SVR). *Journal of Physics: Conference Series*, 1501(1). <https://doi.org/10.1088/1742-6596/1501/1/012012>
- O'Rourke, C. J., Qasim, M. M., Overlin, M. R., & Kirtley, J. L. (2019). A Geometric Interpretation of Reference Frames and Transformations: Dq0, Clarke, and Park. *IEEE Transactions on Energy Conversion*, 34(4). <https://doi.org/10.1109/TEC.2019.2941175>
- Ozdemir, T., Taher, F., Ayinde, B. O., Zurada, J. M., & Ozmen, O. T. (2022). Comparison of Feedforward Perceptron Network with LSTM for Solar Cell Radiation Prediction. *Applied Sciences (Switzerland)*, 12(9). <https://doi.org/10.3390/app12094463>
- P, M., & J, D. K. (2021). Transformer Less Self Commutated PV Inverter. *International Journal of Innovative Technology and Exploring Engineering*, 10(8), 1–4. <https://doi.org/10.35940/ijitee.g9037.0610821>
- Patterson, J., & Gibson, A. (2019). Deep Learning A Practioner's Approach. In *Journal of Chemical Information and Modeling* (Vol. 53, Issue 9).
- Pengcheng, S., & Jiawei, Q. (2021). Research on maximum power point tracking based on LSTM neural network. *Proceedings - 2021 4th International Conference on Advanced Electronic Materials, Computers and Software Engineering, AEMCSE 2021*, 866–869. <https://doi.org/10.1109/AEMCSE51986.2021.00176>
- Phan, B. C., Lai, Y. C., & Lin, C. E. (2020). A deep reinforcement learning-based MPPT control for PV systems under partial shading condition. *Sensors (Switzerland)*, 20(11). <https://doi.org/10.3390/s20113039>
- Photovoltaic Materials and Electronic Devices. (2018). In *Photovoltaic Materials and Electronic Devices*. <https://doi.org/10.3390/books978-3-03842-217-4>
- Pilla, R., Kumar, J. H., & Chandana, A. (2018). Grid tied photovoltaic system with Perturb and Observe maximum power point controller and LCL filter. *International Journal of Engineering and Technology(UAE)*, 7(3). <https://doi.org/10.14419/ijet.v7i3.6.14941>
- Podder, A. K., Roy, N. K., & Pota, H. R. (2019). MPPT methods for solar PV systems: A critical review based on tracking nature. In *IET Renewable Power Generation* (Vol. 13, Issue 10). <https://doi.org/10.1049/iet-rpg.2018.5946>
- Qazi, A., Hussain, F., Rahim, N. A. B. D., Hardaker, G., Alghazzawi, D., Shaban, K., & Haruna, K. (2019). Towards Sustainable Energy: A Systematic Review of Renewable Energy Sources, Technologies, and Public Opinions. *IEEE Access*, 7, 63837–63851. <https://doi.org/10.1109/ACCESS.2019.2906402>
- Quadrelli, R., & Peterson, S. (2007). The energy-climate challenge: Recent trends in CO2 emissions from fuel combustion. *Energy Policy*, 35(11), 5938–5952. <https://doi.org/10.1016/j.enpol.2007.07.001>
- Rai, A. K., Kaushika, N. D., Singh, B., & Agarwal, N. (2011). Simulation model of ANN based maximum power point tracking controller for solar PV system. *Solar Energy Materials and Solar Cells*, 95(2). <https://doi.org/10.1016/j.solmat.2010.10.022>
- Rajkumar, M., & Rathinam, A. (2023). Design and Experimental Investigation of Zeta Converter Fed Reduced Switch Multi-stage Grid Connected Boost MLI. *Journal of Electrical Engineering and Technology*. <https://doi.org/10.1007/s42835-023-01517-9>
- Ram, J. P., Babu, T. S., & Rajasekar, N. (2017). A comprehensive review on solar PV maximum power point tracking techniques. In *Renewable and Sustainable Energy Reviews* (Vol. 67). <https://doi.org/10.1016/j.rser.2016.09.076>



- Ramasamy, P., Sugavanam, V., Vakesan, K., Ramamurthi, S., Kuppusamy, S., Sengamalai, U., & Thentral, T. (2022). Implementation of multicarrier PWM based 7-level Z-source cascaded H-bridge inverter. *International Journal of Power Electronics and Drive Systems*, 13(1). <https://doi.org/10.11591/ijpeds.v13.i1.pp322-329>
- Rehman, A., Ma, H., Ozturk, I., & Ulucak, R. (2022). Sustainable development and pollution: the effects of CO<sub>2</sub> emission on population growth, food production, economic development, and energy consumption in Pakistan. *Environmental Science and Pollution Research*, 29(12), 17319–17330. <https://doi.org/10.1007/s11356-021-16998-2>
- Research Anthology on Artificial Neural Network Applications. (2021). In *Research Anthology on Artificial Neural Network Applications*. <https://doi.org/10.4018/978-1-6684-2408-7>
- Revathy, S. R., Kirubakaran, V., Rajeshwaran, M., Balasundaram, T., Sekar, V. S. C., Alghamdi, S., Rajab, B. S., Babalghith, A. O., & Anbese, E. M. (2022). Design and Analysis of ANFIS - Based MPPT Method for Solar Photovoltaic Applications. *International Journal of Photoenergy*, 2022. <https://doi.org/10.1155/2022/9625564>
- Rodriguez, J., Bernet, S., Steimer, P. K., & Lizama, I. E. (2010). A survey on neutral-point-clamped inverters. In *IEEE Transactions on Industrial Electronics* (Vol. 57, Issue 7). <https://doi.org/10.1109/TIE.2009.2032430>
- Rodriguez, P., Luna, A., Muñoz-Aguilar, R. S., Etxeberria-Otadui, I., Teodorescu, R., & Blaabjerg, F. (2012). A stationary reference frame grid synchronization system for three-phase grid-connected power converters under adverse grid conditions. *IEEE Transactions on Power Electronics*, 27(1). <https://doi.org/10.1109/TPEL.2011.2159242>
- Roh, C. (2022). Deep-Learning Algorithmic-Based Improved Maximum Power Point-Tracking Algorithms Using Irradiance Forecast. *Processes*, 10(11). <https://doi.org/10.3390/pr10112201>
- Roy, R. B., Rokonuzzaman, M., Amin, N., Mishu, M. K., Alahakoon, S., Rahman, S., Mithulananthan, N., Rahman, K. S., Shakeri, M., & Pasupuleti, J. (2021). A Comparative Performance Analysis of ANN Algorithms for MPPT Energy Harvesting in Solar PV System. *IEEE Access*, 9, 102137–102152. <https://doi.org/10.1109/ACCESS.2021.3096864>
- Roy, T. K., & Mahmud, M. A. (2017). Active power control of three-phase grid-connected solar PV systems using a robust nonlinear adaptive backstepping approach. *Solar Energy*, 153, 64–76. <https://doi.org/10.1016/j.solener.2017.04.044>
- Sabri, M., & Hassouni, M. E. (2022). Photovoltaic Power Forecasting With a Long Short-Term Memory Autoencoder Networks. *ResearchSquare*. <https://doi.org/10.21203/rs.3.rs-1777058>
- Sabri, Mohammed, & El Hassouni, M. (2022). Predicting photovoltaic power generation using double-layer bidirectional long short-term memory-convolutional network. *International Journal of Energy and Environmental Engineering*. <https://doi.org/10.1007/s40095-022-00530-4>
- Sahan, B., Araújo, S. V., Nöding, C., & Zacharias, P. (2011). Comparative evaluation of three-phase current source inverters for grid interfacing of distributed and renewable energy systems. *IEEE Transactions on Power Electronics*, 26(8). <https://doi.org/10.1109/TPEL.2010.2096827>
- Salado, J. G. P., Ramírez, C. A. H., Sánchez, A. G. S., & Licea, M. A. R. (2021). Nonlinear stabilization controller for the boost converter with a constant power load in both continuous and discontinuous conduction modes. *Micromachines*, 12(5).

- <https://doi.org/10.3390/mi12050522>
- Salam, M. A., Hegazy, O., & Soliman, O. S. (2015). Comparative Study between FPA, BA, MCS, ABC, and PSO Algorithms in Training and Optimizing of LS-SVM for Stock Market Prediction. In *International Journal of Advanced Computer Research ISSN* (Vol. 3). Higher Technological Institute. <https://www.researchgate.net/publication/274511603>
- Salman, S., Ai, X., & Wu, Z. (2018). Design of a P-&O algorithm based MPPT charge controller for a stand-alone 200W PV system. *Protection and Control of Modern Power Systems*, 3(1). <https://doi.org/10.1186/s41601-018-0099-8>
- Santhoshi, B. K., Mohanasundaram, K., Kaliappan, V. K., & Sathyamurthy, R. (2022). Sinusoidal pulse width modulation for a photovoltaic-based single-stage inverter. *Environmental Science and Pollution Research*, 29(20). <https://doi.org/10.1007/s11356-021-18422-1>
- Senthilkumar, S., V., M., R., D., M., N. S., Kumar, T. S., Thanikanti, S. B., & N., P. (2023). A REVIEW ON MPPT ALGORITHMS FOR SOLAR PV SYSTEMS. *International Journal of Research -GRANTHAALAYAH*, 11(3). <https://doi.org/10.29121/granthaalayah.v11.i3.2023.5086>
- Sevilmi, F., & Karaca, H. (2018). An experimental study of grid tied inverter for renewable energy systems. *2018 International Conference on Smart Energy Systems and Technologies, SEST 2018 - Proceedings*. <https://doi.org/10.1109/SEST.2018.8495826>
- Sevilmiş, F., & Karaca, H. (2021). An Effective Solution to Eliminate DC-Offset for Extracting the Phase and Frequency of Grid Voltage. *Mathematical Problems in Engineering*, 2021. <https://doi.org/10.1155/2021/9742683>
- Shah, R., Mithulanathan, N., Bansal, R. C., & Ramachandaramurthy, V. K. (2015). A review of key power system stability challenges for large-scale PV integration. In *Renewable and Sustainable Energy Reviews* (Vol. 41, pp. 1423–1436). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2014.09.027>
- Sharkawy, A. N., Ali, M. M., Mousa, H. H. H., Ali, A. S., Abdel-Jaber, G. T., Hussein, H. S., Farrag, M., & Ismeil, M. A. (2023). Solar PV Power Estimation and Upscaling Forecast Using Different Artificial Neural Networks Types: Assessment, Validation, and Comparison. *IEEE Access*, 11. <https://doi.org/10.1109/ACCESS.2023.3249108>
- Sharma, S., Sharma, S., & Anidhya, A. (2020). Understanding Activation Functions in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 4(12).
- Sharmin, R., Chowdhury, S. S., Abedin, F., & Rahman, K. M. (2022). Implementation of an MPPT technique of a solar module with supervised machine learning. *Frontiers in Energy Research*, 10(August), 1–15. <https://doi.org/10.3389/fenrg.2022.932653>
- Shayestegan, M. (2018). Overview of grid-connected two-stage transformer-less inverter design. *Journal of Modern Power Systems and Clean Energy*, 6(4), 642–655. <https://doi.org/10.1007/s40565-017-0367-z>
- Sher, H. A., Murtaza, A. F., Noman, A., Addoweesh, K. E., & Chiaberge, M. (2015). An intelligent control strategy of fractional short circuit current maximum power point tracking technique for photovoltaic applications. *Journal of Renewable and Sustainable Energy*, 7(1). <https://doi.org/10.1063/1.4906982>
- SIddaraj, S., Yaragatti, U. R., & Harischandrappa, N. (2023). Coordinated PSO-ANFIS-Based 2 MPPT Control of Microgrid with Solar Photovoltaic and Battery Energy Storage System. *Journal of Sensor and Actuator Networks*, 12(3), 45. <https://doi.org/10.3390/jsan12030045>
- Srinivasan, R., & Ramalingam Balamurugan, C. (2022). Deep neural network based

- MPPT algorithm and PR controller based SMO for grid connected PV system. *International Journal of Electronics*, 109(4), 576–595. <https://doi.org/10.1080/00207217.2021.1914192>
- Suo, C., Zhang, W., Wu, G., Gui, J., Zhao, L., & Ma, C. (2015). Modelling and simulation of MPPT algorithm for PV grid-connected system. *Integrated Ferroelectrics*, 162(1), 18–23. <https://doi.org/10.1080/10584587.2015.1037202>
- Sureshbabu, S., & Aseem, K. (2022). An Efficient Control Scheme Based on PLL Integrated PI Controller for Grid-connected Solar Photovoltaic Systems. *Trends in Sciences*, 19(16). <https://doi.org/10.48048/tis.2022.5699>
- Tarbosh, Q. A., Aydogdu, O., Farah, N., Talib, M. H. N., Salh, A., Cankaya, N., Omar, F. A., & Durdu, A. (2020). Review and Investigation of Simplified Rules Fuzzy Logic Speed Controller of High Performance Induction Motor Drives. *IEEE Access*, 8. <https://doi.org/10.1109/ACCESS.2020.2977115>
- Ting, C. S., Lieu, J. F., Liu, C. S., & Hsu, R. W. (2016). An Adaptive FNN Control Design of PMLSM in Stationary Reference Frame. *Journal of Control, Automation and Electrical Systems*, 27(4). <https://doi.org/10.1007/s40313-016-0243-5>
- Tsantekidis, A., Passalis, N., & Tefas, A. (2022). Recurrent neural networks. In *Deep Learning for Robot Perception and Cognition*. <https://doi.org/10.1016/B978-0-32-385787-1.00010-5>
- Vafaei, S., Gandomkar, M., Rezvani, A., & Izadbakhsh, M. (2015). Enhancement of grid-connected photovoltaic system using ANFIS-GA under different circumstances. *Frontiers in Energy*, 9(3), 322–334. <https://doi.org/10.1007/s11708-015-0362-x>
- Vanti, S., Bana, P. R., D'Arco, S., & Amin, M. (2022). Single-Stage Grid-Connected PV System with Finite Control Set Model Predictive Control and an Improved Maximum Power Point Tracking. *IEEE Transactions on Sustainable Energy*, 13(2), 791–802. <https://doi.org/10.1109/TSTE.2021.3132057>
- Vasquez, V., Ortega, R., Ortega, L. M., Garcia, V. H., & Carranza, O. (2020). Three Phase Four-Wire Inverter for Grid-Disconnected Operation. *IEEE Access*, 8. <https://doi.org/10.1109/ACCESS.2020.3005628>
- Wang, H., Asefa, T., & Thornburgh, J. (2022). Integrating water quality and streamflow into prediction of chemical dosage in a drinking water treatment plant using machine learning algorithms. *Water Supply*, 22(3). <https://doi.org/10.2166/WS.2021.435>
- Wang, K., Qi, X., & Liu, H. (2019). Photovoltaic power forecasting based LSTM-Convolutional Network. *Energy*, 189. <https://doi.org/10.1016/j.energy.2019.116225>
- World Electricity Generation*. (2023, February 28). [https://www.worldenergydata.org/world-electricity-generation/#footnote\\_1\\_9196](https://www.worldenergydata.org/world-electricity-generation/#footnote_1_9196)
- Xue, Yaosuo, Chang, L., Kjær, S. B., Bordonau, J., & Shimizu, T. (2004). Topologies of single-phase inverters for small distributed power generators: An overview. *IEEE Transactions on Power Electronics*, 19(5). <https://doi.org/10.1109/TPEL.2004.833460>
- Xue, Yuntao, & Chen, W. (2023). Multi-Agent Deep Reinforcement Learning for UAVs Navigation in Unknown Complex Environment. *IEEE Transactions on Intelligent Vehicles*. <https://doi.org/10.1109/TIV.2023.3298292>
- YOUNAS, U., BAKİR, H., & KULAKSİZ, A. A. (2019). The Implementation of Effective Modulation Schemes to Improve the Power and Harmonic Losses in Grid-Tied Solar NPC Inverter. *Nevşehir Bilim ve Teknoloji Dergisi*, 8. <https://doi.org/10.17100/nevbiltek.559465>
- Yu, W., Gonzalez, J., & Li, X. (2021). Fast training of deep LSTM networks with guaranteed stability for nonlinear system modeling. *Neurocomputing*, 422.

- <https://doi.org/10.1016/j.neucom.2020.09.030>
- Zeb, K., Uddin, W., Khan, M. A., Ali, Z., Ali, M. U., Christofides, N., & Kim, H. J. (2018). A comprehensive review on inverter topologies and control strategies for grid connected photovoltaic system. *Renewable and Sustainable Energy Reviews*, 94, 1120–1141. <https://doi.org/10.1016/J.RSER.2018.06.053>
- Zhang, L., Sun, K., Li, Y. W., Lu, X., & Zhao, J. (2018). A Distributed Power Control of Series-Connected Module-Integrated Inverters for PV Grid-Tied Applications. *IEEE Transactions on Power Electronics*, 33(9). <https://doi.org/10.1109/TPEL.2017.2769487>
- Zhao, Y., An, A., Xu, Y., Wang, Q., & Wang, M. (2021). Model predictive control of grid-connected PV power generation system considering optimal MPPT control of PV modules. *Protection and Control of Modern Power Systems*, 6(1), 1–12. <https://doi.org/10.1186/s41601-021-00210-1>



I am Umair YOUNAS, originally from Pakistan, and I have recently obtained my PhD in Electrical Electronics Engineering from Selcuk University, Konya, Turkey. Here are the specifics of my educational background and research publications.

| <b>EDUCATIONAL BACKGROUND</b> |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                         |
|-------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Aug 2018 - Feb 2024</b>    | <b>Ph.D. in Electrical and Electronics Engineering (Selçuk University, TURKEY)</b> <ul style="list-style-type: none"> <li>• <b>Project:</b> ‘Deployment of Deep Learning Algorithm for Grid-Tied Solar Energy Systems’</li> <li>• <b>Sponsorship:</b> Funded by the Turkish Government (Türkiye Burslari / 2017-2022)</li> <li>• <b>Specialization:</b> Renewable Energy, Smart Grid, Artificial Intelligence, Optimization, and Control</li> </ul>                                                                                                                                                                                                                                                                                                     |
| <b>Aug 2013 - Jan 2017</b>    | <b>Master of Science in Electrical Engineering (COMSATS PAKISTAN &amp; UniSannio ITALY)</b> <ul style="list-style-type: none"> <li>• <b>Course Work:</b> COMSATS University Abbottabad, PAKISTAN <ul style="list-style-type: none"> <li>– Fully Funded by Workers Welfare Fund WWF – Government of Pakistan</li> </ul> </li> <li>• <b>Research Work:</b> The University of Sannio, ITALY (10-Months Research Project) <ul style="list-style-type: none"> <li>– Fully Funded European Union Mobility Project (Erasmus Mundus LEADER)</li> </ul> </li> <li>• <b>Project:</b> ‘Auxiliary Service Model for Data Centers and Smart Grid’</li> <li>• <b>Specialization:</b> Integration of Renewable Energy, Electric vehicles, Energy Management</li> </ul> |
| <b>Aug 2009 - July 2013</b>   | <b>Bachelor of Science in Electrical and Electronics Engineering (COMSATS University PAKISTAN)</b> <ul style="list-style-type: none"> <li>• <b>Project:</b> ‘Modelling, Simulation, and Control of Industrial Boiler for Thermal Plant’</li> <li>• <b>Sponsorship:</b> Sponsored by Workers Welfare Fund, Government of Pakistan</li> <li>• <b>Specialization:</b> MATLAB / Simulink, Ladder Logic, Programmable Logic Controllers, HMI &amp; SCADA</li> </ul>                                                                                                                                                                                                                                                                                          |
| <b>April 2007 - July 2009</b> | <b>Higher Secondary School Certificate (Govt Post Graduate College Abbottabad, PAKISTAN)</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                            |
| <b>March 2005 - Jun 07</b>    | <b>Secondary School Certificate (Pakistan National Public-School Abbottabad, PAKISTAN)</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                              |

| RESEARCH PUBLICATIONS   |                                                                                                                                                                                                                                                                                                                                        |
|-------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| JOURNAL PUBLICATIONS    |                                                                                                                                                                                                                                                                                                                                        |
| 1.                      | <b>Umair Younas</b> , Ahmet Afsin Kulaksiz, ‘Deep Learning Stack LSTM based MPPT Control of Dual Stage 100 kWp Grid-Tied Solar PV System’, IEEE Access 2024 ( <i>In-Press</i> )                                                                                                                                                        |
| 2.                      | M. Awais, M. Anees, <b>Umair Younas</b> , Ahmet Afsin Kulaksiz, ‘Comparative Assessment of Standalone Solar Photovoltaic Inverter using Proteus and MATLAB Simulink Software’, European Journal of Science and Technology (2021)                                                                                                       |
| 3.                      | <b>Umair Younas</b> , Hale Bakir, Ahmet Afsin Kulaksiz, ‘The Implementation of Effective Modulation Schemes to Improve the Power and Harmonic Losses in Grid-Tied Solar NPC Inverter’, Nevsehir Journal of Science and Technology (2019)                                                                                               |
| 4.                      | <b>Umair Younas</b> , Bayram Akdemir, Ahmet Afsin Kulaksiz, ‘Modeling and simulation of a grid-connected PV system under varying environmental conditions, International Journal of Energy Applications and Technologies 3 (2019)                                                                                                      |
| 5.                      | Kamran Zeb, Waqar U. Din, Muhammad Adil Khan, Ayesha Khan, <b>Umair Younas</b> , Tiago Davi Curi Busarello, and Hee Je Kim, “Dynamic Simulations of Adaptive Design Approaches to Control the Speed of an Induction Machine Considering Parameter Uncertainties and External Perturbations”, energies, 09 (2018) – (Impact Factor 3.2) |
| 6.                      | <b>Umair Younas</b> , B. Khan, S. M. Ali, Alfredo Vaccaro, ‘Fast Performance Computing Model for Smart Distributed Power Systems’, Sukkur IBA Journal of Computing and Mathematical Sciences 6 (2017)                                                                                                                                  |
| 7.                      | <b>Umair Younas</b> , Bilal Khan, Fahad Rehman, S.M. Ali et al. “Pakistan Geothermal Renewable Energy Potential for Electric Power Generation: A Survey”, Renewable & Sustainable Energy Reviews, 63 (2016) 398-413 (Impact Factor 15.9)                                                                                               |
| 8.                      | W. Uddin, B. Khan, N. Shaukat. M. Majid, G. Mujtaba, A. Mehmood, S.M. Ali, <b>Umair Younas</b> et al. “Biogas potential for electric power generation in Pakistan: A survey”, Renewable and Sustainable Energy Reviews, 54 (2016) 25–33. (Impact Factor 15.9)                                                                          |
| CONFERENCE PUBLICATIONS |                                                                                                                                                                                                                                                                                                                                        |
| 1.                      | <b>Umair Younas</b> , Ahmet Afsin Kulaksiz, “Improved Maximum Power Point Tracking of a 100 kWp Grid Tied Solar Photovoltaic System using Recurrent Neural Network”, 9th International Student Symposium (UÖS), 02 December 2023, Istanbul, Turkey                                                                                     |
| 2.                      | <b>Umair Younas</b> , Ahmet Afsin Kulaksiz, “Deep Learning DNN based MPPT Control of 250 W Stand Alone Solar PV System”, 2nd International Technology and Innovation Student Symposium (SUTIS), 7-10 December 2023, Konya, Turkey                                                                                                      |
| 3.                      | <b>Umair Younas</b> , Akif Durdu, Ahmet Afsin Kulaksiz, “Revolutionizing the Healthcare Industry: Real-Time Implementation of AI-Driven Autonomous Robot for Enhanced Delivery Services in Chronic Patient Care”, 7th International Student Sciences Congress (UOK), 15-17 December 2023, Istanbul, Turkey                             |
| 4.                      | <b>Umair Younas</b> , Barış Kokulu, Aysel Banu Tekamah, Bahtiyar Eren Kurt, Akif Durdu, “AI-Driven Service Robot with Docking and Desktop Integrated GUI App for Cafe or Restaurant in Hospitality Industry”, The National Meeting of Automatic Control (TOK), 14-16 September 2023, Istanbul, Turkey                                  |
| 5.                      | <b>Umair Younas</b> , Ahmet Afsin Kulaksiz, “DSP-based Scalar Control of a Three-Phase Induction Motor Powered by Solar Photovoltaic Panels”, 1st International Conference on Computer, Electrical and Electronics Sciences (ICCEES 2020), October 8-10, 2020, Konya, Turkey                                                           |
| 6.                      | <b>Umair Younas</b> , Ahmet Afsin Kulaksiz, “Comparative Assessment of PID and Fuzzy Logic Controller for Speed Control of Variable Load DC Motor”, 6th International Student Symposium (UOS), 5-6 December 2020, Sakarya, Turkey                                                                                                      |
| 7.                      | <b>Umair Younas</b> , Ahmet Afsin Kulaksiz, “DSP-based Scalar Control of a Three-Phase Induction Motor Powered by Solar Photovoltaic Panels”, 1st International Conference on Computer, Electrical and Electronic Sciences (ICCEES), October 8-10, 2020, Konya, Turkey                                                                 |

8. H. Bakir, **U. Younas**, D. Betul, A. Afsin Kulaksiz, “Adaptive Neuro-Fuzzy Interface System-based Energy Management Application for a Residential Photovoltaic On-Grid, International Conference on Energy Research (ENRES), **April 2019 Marmaris Turkey**
9. Yusuf Gurbuz, **Umair Younas**, A. Afsin Kulaksiz, Ahmet Afsin Kulaksiz, “Comparison of Scalar and Vector Control of Induction Motors used in Electric Vehicle Applications”, International Conference on Energy Research (ENRES), **April 2019, Marmaris Turkey**
10. **Umair Younas**, Bilal Khan, S. M. Ali, Tariq Kamal, Alfredo Vaccaro, “Cloud Computing Demand Response and Plugin Electric Vehicles as Energy Management Tool for Smart Grid”, International Conference on Energy Environment and Sustainable Development (EESD), **2016 Jamshoro, Sindh, Pakistan**
11. T. Kamal, M. Nadarajah, S. Z. Hassan, **Umair Younas**, Hina Gohar, Alfredo Vaccaro, “An Intelligent MPPT Design of DCDC Converter for PV in a PV/SC Hybrid Power System”, International Conference on Energy Environment and Sustainable Development (EESD), **2016 Jamshoro, Sindh, Pakistan**
12. S. Z. Hassan, Hui Li, T. Kamal, **Umair Younas**, Qasim Awais, “Synchronization of Hydrogen Energy with Diesel Engine for Distributed Generation Applications”, International Conference on Energy Environment and Sustainable Development (EESD), **2016 Jamshoro, Sindh, Pakistan**
13. **Umair Younas**, Sajjad Durrani, and Yasir Mehmood, “Designing Human Machine Interface for Vehicle’s EFI Engine using Siemen’s PLC and SCADA System”, 13th International Conference on Frontiers of Information Technology (FIT), **14-16 Dec. 2015, Islamabad, Pakistan**
14. Z. Ali, K. Saleem, N. Christofides, A. Rashid, H. Zaman, M. Tahir, and **Umair Younas**, “Performance Analysis of Fuzzy Logic Control and Six-Pulse Line Commutated Converter in DC Motor Drive Application”, International Conference on Emerging Technologies (ICET), **19-20 Dec. 2015, Pakistan**
15. Y. Mehmood, N. Haider, W. Afzal, **U. Younas**; I. Rashid, M. Imran, “Impact of Massive MIMO systems on future M2M communication”, IEEE Malaysia International Conference on Communications (MICC), **26-28 November 2013, Kuala Lumpu, Malaysia**
16. Y. Mehmood, W. Afzal, F. Ahmad, **U. Younas**, I. Rashid, and I. Mehmood, “Large Scaled Multi-User MIMO System so-called Massive MIMO Systems for Future Wireless Communication Networks”, Proceedings of the 19th International Conference on Automation & Computing, **13-14 September 2013, London, UK**