

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY ZEKA TEMELLİ MAKSİMUM GÜÇ NOKTASI TAKİBİ

YÜKSEK LİSANS TEZİ

HALİL İBRAHİM TEMEL

TEZ DANIŞMANI
DOÇ.DR. TOLGA YÜKSEL

BİLECİK, 2021

10372375

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY ZEKA TEMELLİ MAKSİMUM GÜÇ NOKTASI TAKİBİ

YÜKSEK LİSANS TEZİ

HALİL İBRAHİM TEMEL

TEZ DANIŞMANI
DOÇ. DR. TOLGA YÜKSEL

BİLECİK, 2021

10372375

BEYAN

“Yapay Zeka Temelli Maksimum Güç Noktası Takibi” adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel ahlak kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını beyan ederim.

Bu çalışmam, Bilimsel Araştırmalar Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte beyan edilmelidir.			
DESTEK ALINMIŞTIR		DESTEK ALINMAMIŞTIR	
Destek alındı ise;			
Destekleyen Kurum:			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;			

Halil İbrahim TEMEL

.././20..

ÖN SÖZ

Tez çalışmam boyunca her türlü konuda bana yardımcı olan ve desteğini esirgemeyen değerli hocam Doç. Dr. Tolga YÜKSEL’e sonsuz teşekkürlerimi sunarım. Ayrıca lisansüstü eğitim sürecinde bilgi, tecrübe ve destekleri ile yanımda olan Dr. Öğr. Üyesi Ayça KIYAK YILDIRIM ve Dr. Öğr. Üyesi Nazım İMAL’a da teşekkürleri borç bilirim.

Hayatımın her anında olduğu gibi, eğitim hayatım boyunca da beni destekledikleri ve yanımda oldukları için değerli aileme çok teşekkür ederim.

Halil İbrahim TEMEL

.././20..

ÖZET

YAPAY ZEKA TEMELLİ MAKSİMUM GÜÇ NOKTASI TAKİBİ

Çağımızda temiz bir enerji kaynağı olarak fotovoltaik (PV) güç sistemleri göze çarpmaktadır. Bu güç sistemlerinde verimin henüz istenilen düzeyde olmaması bu alanda verimi arttırmaya yönelik çalışmaların önemini arttırmıştır. Verimde, PV panellerinden gelen gerilim, akım, güç ve yükseltici (boost) çeviricinin doluluk-boşluk oranı olan D değeri olmak üzere bu dört parametre oldukça belirleyicidir.

Bu tez çalışmasında literatürde sıklıkla klasik P&O algoritması kullanıldığından MATLAB/SIMULINK'te bulunan şebeke bağlantılı 100 kW PV sistem modeli üzerinde P&O algoritması 2 saniye yürütülmüş ve 20 farklı marka güneş panelinin doluluk-boşluk oranı olan D değeri kaydedilmiştir. MATLAB nntool üzerinde Levenberg-Marquardt algoritması ile (20 x 54609 x 3) boyutlu $V-I$ ve D değerlerinden oluşan veri kümesi kullanılarak öğrenme gerçekleştirilmiştir. Bu öğrenme 428 epokta 0.00626 ortalama karesel hata ile sonuçlanmıştır. LSTM için 2 giriş tek çıkışlı, 80 gizli katmanlı, öğrenme seçeneği olarak "ADAM" algoritmalı, 250 epoklu bir mimari seçilerek öğrenme gerçekleştirilmiştir. MATLAB/SIMULINK'te öğrenilen bu veriler yine MATLAB/SIMULINK'te simüle edilip çalıştırılarak verim karşılaştırması yapılmıştır.

Bu çalışma ile PV sistemlerde derin öğrenme kullanılarak tasarlanan yapay zeka tabanlı MPPT sistemlerinin klasik MPPT algoritmalarına göre daha verimli bir güç sağladığı ve bu alanda yapılacak çalışmalara da rehber olabileceği düşünülmektedir.

Anahtar Kelimeler: Fotovoltaik Sistemler, Yapay Sinir Ağları, LSTM, MPPT, Yükseltici Dönüştürücü, Derin Öğrenme

ABSTRACT

ARTIFICIAL INTELLIGENCE BASED MAXIMUM POWER POINT TRACKING

Photovoltaic (PV) power systems stand out as a clean energy source in our age. The fact that the efficiency of these power systems is not yet at the desired level has increased the importance of efforts to increase efficiency in this field. In efficiency, these four parameter; voltage, current, power coming from the PV panels and the D value, which is the duty cycle of the boost converter, are quite determinant.

In this thesis study, since the classical P&O algorithm is frequently used in the literature, the P&O algorithm was run 2 seconds on the grid-connected 100 kW PV system model in MATLAB / SIMULINK, and the D values of 20 different brands of solar panels were recorded. Learning was realized using the data set consisting of (20 x 54609 x 3) dimensional V-I and D values with the Levenberg-Marquardt algorithm on MATLAB nntool. This learning resulted in 0.00626 mean square error in 428 eppoints. For LSTM, an architecture with 2 inputs, one output, 80 hidden layers, with "ADAM" algorithm as the learning option, and 250 epochs was chosen and the learning was realized. These data learned in MATLAB / SIMULINK were simulated and run in MATLAB / SIMULINK and efficiency comparison was made.

As a result, In PV systems, artificial intelligence-based MPPT systems designed using deep learning provide more efficient power than classical MPPT algorithms. This study is thought to be a guide for the studies to be done in this field.

Keywords: Photovoltaic Systems, Neural Networks, LSTM, MPPT, Boost Converter, Deep Learning.

İÇİNDEKİLER

	Sayfa No
ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
KISALTMALAR LİSTESİ.....	ix
1. GİRİŞ.....	1
1.1 Fotovoltaik Enerji	1
1.2 Maksimum Güç Noktası İzleyicisi (MPPT).....	1
2. LİTERATÜR ÇALIŞMALARI	3
3. MATERYAL.....	9
3.1 YSA (Yapay Sinir Ağları).....	9
3.2 Derin Öğrenme	11
3.2.1 Evrimsel Sinir Ağları.....	12
3.2.2 Tekrarlayan Sinir Ağları	14
3.3 Klasik P&O Algoritması.....	15
4. METOD.....	16
4.1 Eğitim Verilerinin Elde Edilmesi.....	16
4.2 YSA ile Eğitim Aşaması.....	21
4.3 Uzun Kısa Zamanlı Bellek ile eğitim aşaması.....	24
5. SONUÇLAR	28
5.1 Yapay Sinir Ağı ile Eğitim Sonuçları.....	28
5.2 LSTM ile eğitilmiş veriler ile normal verilerin karşılaştırılması.....	31

5.3 LSTM, YSA ve Normal Verilerin Karşılaştırılması	35
KAYNAKÇA	39
ÖZGEÇMİŞ	42

TABLÖLAR LİSTESİ

Tablo 4.1. Seçilen Pv Panellere Ait Elektriksel Parametreler Tablosu	22
---	-----------

ŞEKİLLER LİSTESİ

Şekil 3.1. Yapay sinir hücresinin katman yapısı.....	10
Şekil 3.2. Yapay sinir hücresinin temel yapısı.....	11
Şekil 3.3. Derin Öğrenme, Makine Öğrenmesi ve Yapay Zeka İlişkisi.....	12
Şekil 3.4. Derin öğrenme iş akışı	12
Şekil 3.5. Çok sayıda evrimsel katmana sahip bir ağ örneği.....	14
Şekil 3.6. Tekrarlayan Sinir ağları yapısı.....	14
Şekil 3.7. Klasik P&O algoritması.....	15
Şekil 4.1. MATLAB/SIMULINK Sistem Modeli	16
Şekil 4.2. PV panel dizisi eşdeğer devresi	17
Şekil 4.3. PV panel dizisi Simulink modeli	17
Şekil 4.4. DC Yükseltici Çevirici MATLAB/SIMULINK Modeli	18
Şekil 4.5. DC-DC Çevirici a) devre şeması ve b)Gerilim dalga	18
Şekil 4.6. MATLAB/SIMULINK Şebeke Modeli.....	19
Şekil 4.7. 1Soltech 1STH-350-WH marka panele ait marka ve modelin I-V ve P-V eğrileri .	20
Şekil 4.8. MPPT kullanan Şebekeye Bağlı Fotovoltaik Sistemin Blok Diyagramı	21
Şekil 4.9. Kullanılan YSA yapısı	23
Şekil 4.10. YSA ile D verilerinin eğitilmesi	23
Şekil 4.11. YSA ile D verilerinin eğitilmesi	23
Şekil 4.12. Deep Network Designer a) Katman Yapısı b)Özellikleri.....	25
Şekil 4.13. LSTM Eğitim ilerleme grafiği	26
Şekil 5.1. Yapay Sinir Ağı ile eğitilmiş MATLAB/SIMULINK Sistem Modeli	28
Şekil 5.2. Işıma Grafiği	28
Şekil 5.3. Sıcaklık Grafiği.....	29
Şekil 5.4. Sinir Ağı ile eğitilmiş Ortalama Güç Karşılaştırması	29

Şekil 5.5. Panel gerilimi karşılaştırması.....	30
Şekil 5.6. Panel Akımı Karşılaştırması	30
Şekil 5.7. Sinir Ağı ile eğitilmiş D karşılaştırması	31
Şekil 5.8. LSTM ile Eğitilmiş MATLAB/SIMULINK Sistem Modeli	32
Şekil 5.9. LSTM Ağı ile eğitilmiş Ortalama Güç Karşılaştırması	32
Şekil 5.10. LSTM Ağı ile Eğitilmiş Gerilim Karşılaştırması	33
Şekil 5.11. LSTM Ağı ile eğitilmiş Akım Karşılaştırması	34
Şekil 5.12. LSTM Ağı ile eğitilmiş D Oranı Karşılaştırması.....	34
Şekil 5.13. Ortalama Güç Karşılaştırması.....	35
Şekil 5.14. Gerilim Karşılaştırması.....	36
Şekil 5.15. Akım Karşılaştırması	36
Şekil 5.16. D Karşılaştırması	37

KISALTMALAR LİSTESİ

DC	: Doğru akım
AC	: Alternatif akım
V	: Gerilim
I	: Akım
MPP	: Maksimum güç noktası
MPPT	: Maksimum güç noktası İzleyicisi
ANFIS	: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
PV	: Fotovoltaik
PWM	: Sinyal Genişlik Modülasyonu
GWO	: Gri Kurt Optimizasyonu
PSO	: Parçacık Sürü Optimizasyonu
GSA	: Yerçekimi Arama Algoritması
YSA	: Yapay Sinir Ağı
P&O	: Karşılaştır ve Gözlemle (Perturb and Observe)
IC	: Artırımlı İletkenlik (Incremental Conductance)
D	: Doluluk-boşluk oranı (Duty Cycle)
ADAM	: Uyarlanır Moment Kestrimi (Adaptive Moment Estimation)
LSTM	: Uzun kısa süreli bellek (Long Short-Term Memory)
CNN	: Evrimsel Sinir Ağı
RNN	: Tekrarlayan Sinir Ağı

1. GİRİŞ

1.1. Fotovoltaik Enerji

Bilinen en büyük enerji kaynağı güneştir. Çünkü yaşayan tüm canlıların temel yaşam kaynağı, kullanılan diğer enerji kaynaklarının temelini oluşturur. Güneş enerjisi yenilenebilir ve sınırsız bir özelliktedir.

Enerji ihtiyacının sürekli arttığı bir gerçek olmakla bu ihtiyacın temin edilebilmesi için fosil kaynaklardan ve çevreye zarar veren enerji kaynaklarından daha zararsız ve verimli enerji kaynağı olarak yenilenebilir enerji kaynakları göze çarpmaktadır. Yenilenebilir enerji kaynakları olarak hidroelektrik santralleri, güneş enerjisi santralleri ve rüzgâr enerjisi santralleri başta gelmektedir.

Güneş panelleri üzerine monte edilmiş hücrelerden yapılmaktadır. Bu hücreler güneş ışınlarını elektriğe dönüştürürler.

Güneş enerjisi santralleri birden fazla güneş panelinin birbirleriyle bağlanması ile oluşturulan dizilerden akım ve gerilim elde ederek enerji üretmektedirler. Bu elde edilen doğru akım (DC) elektrik enerjisi de maksimum güç noktası takibi içeren eviriciler ile alternatif akım (AC) 'a dönüştürülmektedir.

Ülkemizde de güneşlenme sürelerinin yeterli düzeyde yüksek olması fotovoltaik sistemlere hem yatırım hem de enerji ihtiyacına çözüm amacıyla yönelmeleri arttırmakta ve güneş enerjisi santrallerinin kurulumunu arttırmıştır.

1.2. Maksimum Güç Noktası İzleyicisi (MPPT)

Maksimum Güç Noktası İzleyicisi (MPPT), güneş panellerinden elektrik üretimi yapımında kullanılan önemli bir teknoloji olup, coğrafi şartlara göre değişen güneşin konumuna, hava şartlarına ve çevresel koşullara bağlı olarak üretilen elektrik enerjisinde maksimum verimlilik elde etmeyi sağlar.

Fotovoltaik sistemler maliyetlerinin yüksekliği, sıcaklık, güneşlenme-gölgelenme süresi ve sürekli değişen koşullara bağlı olarak verim açısından dezavantajlara sahiptir. Üretilen PV paneller % 100 verime sahip değildirler. Ancak bu panellerin çok iyi verime sahip olmamaları mevcut değişen şartlardaki ışınım miktarı ve sıcaklıklarda maksimum verimi elde edilmesine yönelik çalışmalara engel değildir. Bir PV sistemin çıkışındaki güç değerinin maksimum olduğu gerilim ve akım grafiğindeki nokta maksimum güç noktasıdır. PV paneller MPP'de

bulunduđu anda en iyi güç çıkışını verir. Bu MPP'de çalışmayı sağlamak için MPPT sistemleri tasarlanmışlardır.

Bu dezavantajların asgariye indirilmesinin çevresel etki ile uyumlu olarak çalışabilmesine bağlı olduğundan maksimum güç elde etme amacıyla MPPT sistemleri tasarlanmıştır. Tasarlanan MPPT sistemleri bir dönüştürücü ve bir denetleyiciden oluşmaktadır.

MPPT sistemlerinde karar verme döngüleri içeren algoritmalar kullanılır. Bu algoritmalar PV sistemin sürekli MPP noktasında çalışmasını sağlamaya yönelik çalışmaktadırlar. Bu algoritmalarda, panel akımı, panel gerilimi, ışınım miktarı, sıcaklık gibi değerler sensörler yardımıyla kullanılır.

Güneş panellerinin verimlerini arttırmak için kullanılan birçok MPPT algoritmaları vardır. Kullanılan MPPT algoritmaları geleneksel MPPT algoritmaları ve zeki MPPT algoritmaları olarak iki çeşittir. Geleneksel MPPT algoritmaları değiştir&gözle yöntemi (P&O, Perturb & Observe), artan iletkenlik yöntemi (IC, Incremental Conductance) ve tepe tırmanışı yöntemi (HC, Hill Climbing), açık devre yöntemi, kısa devre yöntemidir. Zeki MPPT algoritmaları ise Yapay Sinir Ağları (YSA), Bulanık Mantık ve Parçacık Sürüşü Optimizasyonu (PSO) yöntemleridir.

MPPT sistemlerinde verim ölçümü için Avrupa Standardı olan EN 50530 geliştirilmiştir. Kullanılan MPPT yöntemi ile tüm sistemin dinamik çevre koşulları altındaki performansını bu standart tayin etmektedir. MPPT algoritmalarının verimleri bu standarda göre değerlendirilmektedir.

Gelişen teknoloji ile birlikte PV paneller toplam elektrik enerjisi üretiminde enerji üretim paylarını artırmaktadır. Bu artışla beraber operasyonel güç panellerinin çeşitliliği ve verimliliği daha da önem kazanmaktadır. Bu çalışmada, MATLAB/SIMULINK altında tanımlanan 100 kW şebeke bağlantılı PV dizisine dayalı olarak, farklı şirketlerin panelleri için karşılaştı ve gözlemle (Perturb and Observe-P&O) yerini alacak YSA tabanlı bir model oluşturulacaktır. Bir MPPT sisteminde, PV dizi çıkışındaki voltaj, bir yükseltici dönüştürücü yardımıyla artırılır ve ardından şebeke için AC'ye çevrilir. Bu çalışmada, 20 farklı güneş paneli firmasının aynı gücünü sağlayan yükseltici dönüştürücü için gerekli olan doluluk-boşluk oranı (duty cycle) değerini belirlemek için YSA tabanlı bir yaklaşım tanımlanacaktır.

2. LİTERATÜR ÇALIŞMALARI

Tez çalışması ile ilgili kapsamlı literatür taraması yapılmıştır. Konu ile ilgili makaleler ve tezler incelenmiştir. Ve aşağıda özetleri sunulmuştur.

Verma vd., (2015) yaptıkları çalışmada 31 MPPT tekniğinin bir özeti ve 13 parametreye göre sınıflandırılması yapıldığını, üzerinde çalışılan karşılaştırmalı analizin, hem operatörlerin hem de tüketicilerin gereksinimlerini karşılamak için en yapıcı ve uyumlu MPPT türünü seçmede rehberlik edebilecek çarpıcı bir araç olabileceğini, hem sistemin hem de çevre şartlarının istediği tüm niteliklerine daha uygun olduğu anlaşılan mükemmel MPPT seçiminin yorucu işindeki karmaşıklığı önleyeceğini, bu bilginin araştırmacılara hâkim endüstriyel senaryo bağlamında yardımcı olmak için çekici bir kaynak olarak bulunabileceğini belirtmişlerdir. (Verma vd, 2015: 1029)

Liu vd., (2015) yaptıkları çalışmada tek tip ve kısmi gölgeleme koşulları altında normal MPPT yöntemleri, optimum izleme yöntemini bulmak için bir çalışma yaptıklarını, MPPT ve verimlilik sağlama çalışmasının halen çok güncel bir araştırma alanı olduğunu, kısmi gölgelenmeli MPPT çalışmalarında YSA, PSO ve Fibonacci gibi akıllı tekniklerde artan bir yönelim olduğunu, mevcut MPPT yöntemlerinde kısmi gölgelenmeli panellerin verimlerinde düşüklük olduğunu, doğru matematiksel modeli tahmin etmenin, etkin MPPT stratejisini gerçekleştirmek için gerekli olduğunu ve görüntü işleme tekniğinin de maksimum noktayı tahmin etmek için kullanılabileceğini belirtmişlerdir. (Liu vd., 2015: 1505)

Ram vd., (2016) yaptıkları çalışmada MPPT arenası altında önerilen araştırma makaleleri dikkatlice incelendiğini ve ayrıca MPPT tekniklerindeki zorlukları analiz eden çalışmaları her alt bölümde listelendiğini, çalışma, son yıllarda MPPT uygulamasında kıyaslanan en yaygın kullanılan teknikler üzerinde yapıldığını, her algoritmada yer alan karmaşıklık ve dinamik hava koşulları altında evrimsel algoritmaların güvenilir performansının kısaca analiz edildiğini, tasarım değerlendirme, performans analizi, doğruluk ve donanım uygulama sürecini ele alan bir iç çalışma gerçekleştirildiğini, anketten yakın zamanda gelişen parçacık optimizasyon tekniklerinin, arama yeteneği ve yakınsama hızı açısından olumlu tepkiler aldığının çok açık olduğunu belirtmişlerdir. (Ram vd., 2016: 843)

Ramli vd., (2016) yaptıkları çalışmada normal koşullardaki PV sistemleri ve kısmi gölgeleme koşulları (Partial Shading Conditions-PSC) için MPPT yöntemlerinin kapsamlı bir incelemesi yapıldığını, MPPT yöntemleri ayrıca yapay zeka tabanlı, hibrit ve diğer MPPT yöntemleri olarak kategorize edildiğini, Normal şartlar altında MPPT yöntemleri ile PSC

üzerinde yapılan araştırmaların karşılaştırılması, araştırmacıların son birkaç yıldan beri PSC'ye daha fazla odaklandığını ortaya koyduğunu, Bunun PV sistemlerinin güç çıkışını ve verimliliğini artırma ihtiyacından kaynaklanıyor olduğunu belirtmişlerdir.(Ramli vd.,2016: 152)

Anzalchi ve Sarwat (2017), yaptıkları çalışmada MPPT yöntemlerini analiz ederek şebekeye uyumluluk sorunlarında iyileştirme yapmaya çalışmışlardır. Makalede merkezi eviricili, dizi eviricili, çoklu dizi ve modül eviricili konfigürasyonlar üzerinde şu sonuca varmışlardır. Verim ve performans bakımından kıyaslandığında iyiden kötüye doğru şu şekilde sıralamışlar, 1- Modül evirici, 2- dizi evirici, 3- çoklu dizi evirici ve 4-merkezi evirici. (Anzalchi ve Sarwat, 2017: 312-327)

Kulaksız (2007), yaptıkları çalışmada genetik algoritma (GA) yardımcı yapay sinir ağı (YSA) tabanlı algoritma kullanarak MPPT yapmaya çalışmışlardır. Çalışma gerçekleştirilerek DSP ile 2 adet 60 W panel olmak üzere 120 W güce sahip bir PV ile yük tarafında bir asenkron motorun bulunduğu sistem üzerinde gerçekleştirilmiştir. Yöntem giriş olarak gerilim ve açı değerleri almakta ve çıkış olarak DSP'nin PWM çıkış sinyali vermektedir. GA optimizasyonunun kullanılmadığı YSA yapısını içeren MPPT algoritması için bulunan değerlere göre PV panel gücünün ortalama olarak %95.14'ü kullanılabilirken, GA optimizasyonlu YSA yapısını içeren MPPT algoritması için %97.58'inin kullanılabildiği olarak bulunarak karşılaştırma yapılan çalışmada daha iyi verim sağlanmıştır. Önerilen algoritmada frekanstaki değişim miktarı maksimum güç noktasına kadar nispeten yüksek değerler alırken, maksimum güç noktasına ulaşılmasının ardından düşük değerler almakta ve bu da salınımların azalmasına yol açmaktadır. (Kulaksız, 2007: 84)

Erdoğan (2011), yaptıkları çalışmada ANFİS kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon ile 55 W güce sahip bir sistem üzerinde gerçekleştirilmiştir. Yöntem giriş olarak boşluk diyotuna bağlı FV hücre grubunun gerilimleri almakta ve çıkış olarak da çıkış gerilimi de hangi aralıkta ise o aralığın ortalama değerini vermektedir. Klasik P&O veya Hill Climbing yöntemleri ile karşılaştırma yapılan çalışmada önerilen yöntemin, seri bağlı iki modülden oluşan FV sistemde %21.11 seri bağlı dört FV modülden oluşan FV sistemde %7.98 daha verimli olduğu sağlanmıştır. (Erdoğan, 2011: 29)

Çakmak (2012) yaptıkları çalışmada bulanık mantık algoritması kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB ile 8428.56 W miktarı bir sistem üzerinde gerçekleştirilmiştir. Yöntem/birim giriş olarak panel gerilim ve akım değerleri sinyallerini alarak de ve e parametrelerini bulanık mantık denetleyicisine giriş değerleri olarak almakta ve çıkış olarak du kullanılarak Vref çıkış değerini vermektedir. P&O ile karşılaştırma yapılan

çalışmada maksimum gücün takibi hızlı ve yumuşak bir şekilde gerçekleştirilmesi ve bataryanın etkin kullanımı gerçekleştirilerek gücün sürekliliği sağlanmıştır. Her bir çevrimdeki adım değeri değişken tutulmuştur. Maksimum güç noktasına uzak olduğu anda büyük adım değerleri uygulanırken maksimum güç noktasına yakın olduğunda küçük adım değerleri uygulanmıştır. (Çakmak, 2012: 66)

Çetinbaş (2014), yaptıkları çalışmada YSA, BM ve PSO kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB ile 180 W'lık bir sistem üzerinde gerçekleştirilmiştir. Yöntem giriş olarak sıcaklık, ışıınım ve DC gerilim almakta ve çıkış olarak DC akım vermektedir. Klasik MPPT yöntemleri ile karşılaştırma yapılan çalışmada izleme ve hesaplama hızı daha yüksek ve gerçek MPPT noktası tahmininde iyi sonuçlar sağlanmıştır. (Çetinbaş, 2014: 56)

Çelik (2015), yaptıkları çalışmada yeni bir P&O ile YSA tabanlı hibrid algoritma kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak PSCAD/EMTDC ile 13 kW miktarı bir sistem üzerinde gerçekleştirilmiştir. Yöntem/birim giriş olarak sıcaklık ve ışıma giriş değerlerini almakta ve çıkış olarak maksimum güç noktası izleyici gerilimini vermektedir. Klasik IC ve P&O teknikleri ile karşılaştırma yapılan çalışmada güç akışının iyileşmesi sağlanmıştır. Her bir çevrimdeki adım değeri öğrenme algoritmaları ve gizli katmanların sayısı ile değişken tutulmuştur. (Çelik, 2015: 47)

Işık (2015), yaptıkları çalışmada bulanık mantık algoritması kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB üzerinde 4 kol ve her kolunda 7 seri bağlı 325.221 W'lık güneş panellerinden oluşan bir sistem üzerinde gerçekleştirilmiştir. Yöntem/birim giriş olarak akım ve gerilim sinyallerinden hata ve CE sinyalleri almakta ve çıkış olarak gerilim ve adım değerleri sinyallerini vermektedir. Klasik P&O ve IC metotları ile karşılaştırma yapılan çalışmada bu algoritmanın güç noktasını %99.9 doğrulukta takip edebildiği sağlanmıştır. Her bir çevrimdeki adım değeri değişken tutulmuştur. Akım gerilim okuyarak adım değerinin değişken olması sağlanmıştır. (Işık, 2015: 45)

Ardıç (2015), yaptıkları çalışmada ANFİS algoritmasını kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB ile 60 W güce sahip bir sistem üzerinde gerçekleştirilmiştir. Yöntem giriş olarak ışıma, sıcaklık, gerilim ve akım sinyallerini almakta ve çıkış olarak gerilim, akım ve güç sinyallerini vermektedir. Klasik P&G ile karşılaştırma yapılan çalışmada verim artışı ve performans artışı sağlanmıştır. Her bir çevrimdeki adım değeri sabit tutulmuştur. (Ardıç, 2015: 44)

Gökdağ (2016), yaptıkları çalışmada yeni bir MPPT algoritması kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak PSpice ile 318.06 W güce sahip bir sistem üzerinde gerçekleştirilmiştir. Yöntem giriş olarak hücre ışıma(gölgelenme) sinyalleri almakta ve çıkış olarak güç sinyalini vermektedir. Klasik MPPT yöntemleri ve atlama diyotu ile tasarlanan paneller ile karşılaştırma yapılan çalışmada test edilen kısmi gölgelenme şartları için boşluk diyotlu seri dizine göre toplam % 10-20 oranında fazla güç elde edilmesini sağlamıştır. (Gökdağ, 2016: 35)

Bakım (2016), yaptıkları çalışmada yeni bir P&O tabanlı algoritma kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB/SIMULINK ile 250 W güce sahip bir sistem üzerinde gerçekleştirilmiştir. Klasik P&O algoritması ile karşılaştırma yapılan çalışmada verim artış miktarı % 0.15 daha fazla verim sağlanmıştır. Her bir çevrimdeki adım değeri sabit tutulmuştur. (Bakım, 2016: 18)

Hacı (2016), yaptıkları çalışmada ANFİS algoritması kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB/SIMULINK ile 250 W gücünde bir sistem üzerinde gerçekleştirilmiştir. Sistem giriş olarak ışıma ve sıcaklık değerlerini almakta ve çıkış olarak akım, gerilim ve güç sinyallerini vermektedir. Klasik karşılaştırma yapılan yöntem adı P&O ile karşılaştırma yapılan çalışmada daha verimli bir güç sağlanmıştır. Her bir çevrimdeki adım değeri sabit tutulmuştur. (Hacı, 2016: 34)

Kocabaş (2017) yaptıkları çalışmada bulanık mantık yöntemi kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak çalışma ortamı MATLAB/SIMULINK ile 305.20 W miktarı bir sistem üzerinde gerçekleştirilmiştir. Giriş olarak ışıma ve sıcaklık ile gerilim ve akım değerlerini almakta ve çıkış olarak PWM sinyali vermektedir. Klasik yöntemlerde %89.5 iken yapılan yeni çalışmada MPPT verimliliği yaklaşık %95 çıkmıştır.(Kocabaş, 2017:38)

Başoğlu (2017) yaptıkları çalışmada SEPIC dönüştürücü yöntemi kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB/SIMULINK ile 300 W miktarı bir sistem üzerinde gerçekleştirilmiştir. Yöntem/birim giriş olarak akım ve gerilim sinyallerini almakta ve çıkış olarak PWM sinyalini vermektedir. Klasik P&O algoritması ile karşılaştırma yapılan çalışmada Önerilen algoritmanın MPPT verimi %99.4 iken, değiştir gözle algoritmasının verimi %98.52 tespit edilmiştir. Her bir çevrimdeki adım değeri sabit tutulmuştur. (Başoğlu, 2017: 34)

Tüysüz (2018), yaptıkları çalışmada Bulanık Denetleyici Optimizasyonu ile MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB/SIMULINK ile 15 kW değerinde hem fotovoltaiik hem de rüzgâr enerjisi santrali için tasarlanan sistem üzerinde gerçekleştirilmiştir. Yöntem giriş olarak RES ve GES gerilim ve akımlarını almakta ve çıkış olarak PWM vermektedir. Klasik P&O ile karşılaştırma yapılan çalışmada optimizasyon sağlanmıştır. Her bir çevrimdeki adım değeri sabit tutulmuştur. (Tüysüz, 2018: 59)

Madı (2018), yaptıkları çalışmada Ateş Böceği Algoritması kullanılarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB/SIMULINK ile 271.45 W miktarı bir sistem üzerinde gerçekleştirilmiştir. Yöntem giriş olarak akım ve gerilim sinyalleri almakta ve çıkış olarak PWM sinyalini vermektedir. Her bir çevrimdeki adım değeri değişken tutulmuştur. Işınım değişikliği veya sıcaklık değişikliğinde herhangi bir değişiklik olursa adım değeri de bu değişikliğe göre değişmektedir. (Madı, 2018: 39)

Arpacı (2019) yaptıkları çalışmada P&O metodu, bulanık mantık metodu ve ANFIS metodu tabanlı MPPT algoritmaları kullanarak MPPT yapmaya çalışmışlar ve doğrusal olmayan farklı parametreler altında MPPT'lerin performansı karşılaştırılmıştır. Çalışma simülasyon olarak MATLAB/SIMULINK ortamında ile 249.86 W güce sahip bir PV panel sistemi üzerinde gerçekleştirilmiştir. Yöntem giriş olarak PV panelin gerilim ve akım değerlerini almakta ve çıkış olarak doluluk-boşluk oranı (duty cycle) değerini vermektedir. ANFIS kontrolörüne bulanık mantık kontrolörlerine kıyasla hız ve verimlilik izleme açısından çok iyi sonuçlar sağlanmıştır. P&O bazlı MPPT kontrolörünün verimliliği yaklaşık %87 olarak ve MPP noktasına ulaşma süresinin 0.4 – 0.5 saniye olduğu, bulanık mantık tabanlı MPPT kontrolöründe ise 0.04-0.05 s zaman aralığında maksimum değerlerine ulaştığı ve %98 verimlilik elde ettiği, ANFIS tabanlı MPPT kontrolörünün ise kısmi gölgeleme sırasında öngörülemeyen ışınlama seviyesi değişikliklerine karşı dayanıklılık göstermiş, kısmi gölgeleme koşullarında daha yüksek verimlilik ve daha hızlı izleme hızı elde edilmiştir. (Arpacı, 2019:42)

Aydoğan (2019) yaptıkları çalışmada parçacık sürü optimizasyonu yöntemi kullanarak MPPT yapmaya çalışmışlardır. Çalışma simülasyon olarak MATLAB/SIMULINK ortamında ile 900 W miktarı bir sistem üzerinde gerçekleştirilmiştir. Yöntem giriş olarak ışıma, sıcaklık, akım, gerilim ve güç sinyallerini almakta ve çıkış olarak çıkış gücünü vermektedir. Klasik evirici çıkış gücünün panel katalog çıkış gücüne oranı ile bu çalışma sonucunda evirici çıkış gücünün evirici giriş gücüne oranının farkı olarak %0,44 verim artışı sağlanmıştır. (Aydoğan, 2019: 47)

Zorlu (2019), yaptıkları çalışmada bulanık mantık yöntemi kullanarak MPPT yapmaya çalışmışlardır. Çalışma gerçekleştirme olarak ARM tabanlı bir mikroişlemci ile 130 W miktarı bir

sistem üzerinde gereklenmiřtir. Yöntem giriř olarak gerilim deęerleri, foto diren deęerleri ve bu deęerlerin anlık geri besleme deęerleri almakta ve ıkıř olarak dnüş bilgisi deęiřkeni bir motor sürücü devresinin giriř parametresi olarak kullanılmakta ve maksimum gücün saęlandığı noktaya yönelimini vermektedir. Klasik yöntemler olan P&O, IC ile karşılařtırma yapılan alıřmada verim artışı saęlanmıřtır. Her bir evrimdeki adım deęeri sabit tutulmuřtur. (Zorlu, 2019: 54)

Keskin (2019), yaptıkları alıřmada literatür tarama sonrası hazırlanan Adaptif algoritma kullanarak MPPT yapmaya alıřmıřlardır. alıřma gerekleme olarak Arduino ile 14.07 W deęerinde bir sistem üzerinde gereklenmiřtir. Yöntem giriř olarak gerilim ve akım sinyalleri almakta ve ıkıř olarak PWM sinyalini vermektedir. Klasik Deęiřtir ve Gözle, Arttırımlı İletkenlik ve her ikisinin birlikte kullanıldığı MPPT metodu ile karşılařtırma yapılan alıřmada elde edilen güç verilerinin ortalama deęerleri birbirlerine yakın oldu tespit edilmiřtir. Her bir evrimdeki adım deęeri deęiřken tutulmuřtur. Bu deęiřkenlik dP/dV oranı sabit adım büyüklüğü yerine doğrudan hesaplamada kullanılmıřtır. Deęiřtir ve Gözle yönteminde sadece bu oran hesaplamada kullanılmıřken Artan İletkenlik yönteminde ise dP/dV oranı ile birlikte akım verisi de adım büyüklüğü hesaplamaktadır. (Keskin, 2019: 38)

Aygöl (2019), yaptığı alıřmada Kelebek Optimizasyon Algoritması (Butterfly Optimization Algorithm-BOA) metodu kullanarak MPPT yapmaya alıřmıřtır. alıřma simölasyon olarak MATLAB ile 250 W kapasiteli bir sistem üzerinde gereklenmiřtir. Yöntem giriř olarak gerilim ve akım deęerlerini almakta ve ıkıř olarak PWM sinyalini vermektedir. Literatürdeki Gri Kurt Optimizasyonu (Gray Wolf Optimization- GWO), Paracık Sürü Optimizasyonu (Particle Swarm Optimization-PSO) ve Yerekimi Arama Algoritması (Gravitational Search Algorithm-GSA) ile karşılařtırma yapılan alıřmada BOA yönteminin MPPT görevinde yüksek doğruluk ve PSO-GSA ve GWO yöntemlerinden daha yüksek hız saęlanmıřtır. Ancak verim deęerlerinin birbirlerine yakın olduęu tespit edilmiřtir. Her bir evrimdeki adım deęeri sabit tutulmuřtur. (Aygöl, 2019: 47)

3. MATERYAL

Bu tez çalışmasında MPPT'ye bağlı yükseltici çeviricinin doluluk-boşluk oranını belirlemek üzere yapay zeka birimlerinin kullanılması hedeflenmiş ve yapay zeka birimi olarak yapay sinir ağları ve derin öğrenme tabanlı uzun kısa dönem bellek birimi kullanılmıştır. Bu yapay zeka birimlerine ait genel özellikler izleyen alt bölümlerde verilmiştir.

3.1. YSA (Yapay Sinir Ağları)

Sistemden gelen bilgilerin işlenmesi, yorumlanması, hatanın konumu ve boyutu ile ilgili sonuca varmak oldukça önemlidir. Normalde bu işlem uzman bir kişi tarafından yapılır. Bu ise hem kişiye bağımlı olunması hem de zaman tasarrufu açısından çok kullanışlı değildir.

Hata teşhisinde son zamanlarda yapay zekâ tabanlı sistemler teşhis amaçlı kullanılmaktadır. “İnsanların bilgisayarlardan daha iyi yaptıkları işleri bilgisayarların yapabilmesi için çalışan bilim dalıdır” (Sağıroğlu,2003) şeklinde yapay zekanın tanımı yapılmıştır. İlk defa 1956 yılında kullanılan bu terim “Makineleri zeki yapan mühendislik ve bilim dalı” olarak da bilinmektedir (Crevier, 1993). En sık kullanılan yapay zekâ yöntemleri; YSA, bulanık mantık ve genetik algoritma yöntemleridir.

YSA insanın yapısında var olan sinir sistemlerinden esinlenerek oluşturulmuş bilgisayar programlarıdır. (Erdem ve Uzun, 2005). YSA modeli ilk kez 1943 yılında, tıpçı Warren McCulloch ile matematikçi Walter Pitts tarafından oluşturulmuştur. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı gerçekleştirmişlerdir. 1949 yılında ise Hebb "Organization of Behavior" adlı eserinde öğrenme ile ilgili temel teoriyi ele almış ve yine eserinde öğrenebilen ve uyum sağlayabilen sinir ağları modeli için temel oluşturacak "Hebb kuralı"nı ortaya koymuştur.


1957 yılında Frank Rosenblatt beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar neticesinde ortaya çıkan tek katmanlı eğitilebilen ve tek çıkışa sahip bir ağ model olan Perceptron'u geliştirmesinden sonra, YSA ile ilgili çalışmalar hız kazanmıştır (Elmas,2003). Bernard Widrow ve Marcian Hoff tarafından 1959 yılında ADALINE (Adaptive Linear Neuron) modeli geliştirildi ve bu model YSA'ların mühendislik uygulamaları için başlangıç kabul edildi.

YSA'lar simüle edilen sinir hücreleri (nöronlar) içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağ oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, YSA'lar, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm

üretmektedir. Bir insanın, düşünme ve gözlemlene yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir.

YSA'ların doğrusal olmamaları, öğrenme kabiliyetlerinin olması, genelleme yapabilmeleri, adaptasyon kabiliyetlerinin olması, gürültüye karşı toleranslarının olması, donanımsal olarak gerçekleştirilebilmeleri, paket yazılımlarının bulunması avantajlarından bazıları olarak göze çarpmaktadır. Bu nedenle birçok alanda kullanılır duruma gelmiştir. Sınıflandırma, Modelleme ve Tahmin uygulamaları bu alanlardan başlıcalarıdır.

YSA genel yapıda 3 temel katmanın paralel yapıda bir araya gelmesiyle oluşur (Bozkurt, 2008). Bu katmanlar giriş katmanı, ara katmanlar ve çıkış katmanıdır ve şekil 3.1'de gösterilmektedir. Giriş katmanı YSA' da kullanılacak ve dış ortamdan gelen bilgilerin sisteme giriş yaptığı yer olarak adlandırılır. Gizli katman da denilen ara katman bir veya birden fazla yapıda olabilmektedir. Bilgilerin işleme tabii tutulduğu kısımdır. Çıkış katmanı ise; ara katmandan gelen bilgileri işleyerek giriş katmanından gelen bilgilere göre çıkış üretilen kısımdır.




Şekil 3.1. Yapay sinir hücresinin katman yapısı

Kaynak: (Kutlu, Badur, 2009: 29)

YSA algoritmaları mimari yapılarına göre; geri beslemeli, ileri beslemeli olarak tasnif edilirken, öğrenme yaklaşımlarına göre ise; danışmalı öğrenme, danışmasız öğrenme ve

takviyeli öğrenme olarak tasnif edilirler. YSA hücrelerinin bağlantı durumlarına, aktivasyon fonksiyonlarına ve öğrenme kurallarına göre çeşitli YSA yapıları bulunmaktadır.

YSA'da her bir giriş sinyali bir kazanç veya ağırlık ile çarpılır ve toplayıcı düğümünde ağırlıkla çarpılan tüm giriş sinyallerinin ve öndeğer sinyalinin toplamı alınır ve çıkışa bir aktivasyon fonksiyonu boyunca aktarılmaktadır. Bu aktarım şekil 3.2'de gösterilmektedir.



Şekil 3.2. Yapay sinir hücresinin temel yapısı


Kaynak: (Zafari vd., 2013: 9)

Ağırlıkların değerleri geriye yayılım algoritmasıyla hataların çıkıştan girişe doğru geriye doğru etkilerinin dağıtılması ile hesaplanmaktadır. (Bozkurt, 2008: 24).

3.2. Derin Öğrenme

Derin öğrenme; denetimli veya denetimsiz özellik çıkarma, dönüştürme, desen analizi ve sınıflandırma için birçok doğrusal olmayan ara katmandan faydalanan bir makine öğrenme teknikleri sınıfı şeklinde tanımlanmıştır. (Deng&Yu, 2013: 197)

Derin öğrenme, insanın en önemli organı olan beynin bilgiyi alma, işleme ve karar vermek için model oluşturmasını kendine amaç edinen bir yapay zekâ yetisidir. Yapay zekanın, düzenlenmemiş ve sınıflandırılmamış bilgilerden öğrenebilen bir makine öğrenmesi olarak da tanımlanmaktadır. Ayrıca derin sinir ağı da denilmektedir. Yapay zekanın kullanılabilmesi için derin öğrenme algoritmalarının işlevi büyüktür. Kontrollü ya da kontrolsüz öğrenme kullanılarak yapay zekâ eğitilebilir. Şekil 3.3'te de görüldüğü gibi derin öğrenme makine öğrenmesinin, makine öğrenmesi de yapay zekanın bir alt kümesidir.




Şekil 3.3. Derin Öğrenme, Makine Öğrenmesi ve Yapay Zeka İlişkisi

Derin öğrenme algoritmaları evrişimsel ve tekrarlayan sinir ağları olmak üzere izleyen alt bölümlerde açıklanmıştır. Tez çalışması kapsamında tekrarlayan sinir ağlarından türetilmiş olan LSTM birimi kullanılmıştır.

Aşağıda tez çalışmasında kullandığımız derin öğrenme algoritmaları anlatılacaktır.

3.2.1. Evrişimsel Sinir Ağları

Evrişimsel sinir ağları (convolutional neural network-CNN) verileri işlemede profesyonelleşmiş bir sinir ağı çeşididir. David Hubel ve Torsten Wiesel tarafından memeli hayvanların görme sistemi hakkındaki çalışmaları CNN modelinin en temeli olarak söylenebilir (YAVUZ, 2020: 20). CNN, derin öğrenme algoritmalarının en önemlilerinden biri olup, verilerin sınıflandırmasını yapabilmektedir. CNN mimarileri girdi olarak iki boyuta sahip veriler ile çalışmaktadır. CNN, katman tipi olarak üç ana katman kullanmakta ve bunlar sırasıyla evrişimsel katmanlar, tamamen bağlı katmanlar ve ortaklama katmanlarıdır. CNN parametrelerinin eğitimi için geleneksel geri yayılım algoritmasına temel olan yöntemler kullanılmaktadır.



Şekil 3.4. Derin öğrenme iş akışı

Kaynak: (MATLAB, 2020)


CNN'ler manuel özellik çıkarma ihtiyacını ortadan kaldırıp özelliklerin doğrudan öğrenmesi, son teknoloji ürünü tanıma sonuçları üretmesi, yeni tanıma görevleri için yeniden eğitilebilir olması ve bunun da önceden var olan ağlar üzerine inşa etmeyi sağladığı için popüler hale gelmiştir. Şekil 3.4'te gösterildiği üzere görüntüler, özellikleri otomatik olarak öğrenen ve nesneleri sınıflandıran CNN'ye aktarılır. CNN'ler, görüntü tanıma ve görüntü algılama için optimal bir mimari sağlamaktadır. GPU'lar ve paralel hesaplamadaki gelişmelerle birleştiğinde, CNN'ler, otomatik sürüş ve yüz tanıma alanındaki yeni gelişmelerin altında yatan önemli bir teknolojidir. Örneğin, derin öğrenme uygulamaları, kanser hücrelerini görsel olarak tespit etmek için binlerce patoloji raporunu incelemek için CNN'leri kullanır. CNN'ler ayrıca sürücüsüz arabaların nesneleri algılamasını ve bir sokak tabelası ile yaya arasındaki farkı anlamayı öğrenmesini sağlamaktadır.

CNN, her biri bir görüntünün farklı özelliklerini algılamayı öğrenen onlarca veya yüzlerce katmana sahip olabilir. Filtreler, her eğitim görüntüsüne farklı çözünürlüklerde uygulanır ve her bir kıvrımlı görüntünün çıktısı, bir sonraki katmana girdi olarak kullanılır. Filtreler, parlaklık ve kenarlar gibi çok basit özellikler olarak başlayabilir ve nesneyi benzersiz şekilde tanımlayan özelliklerin karmaşıklığını artırabilir. CNN'ler görüntü, metin, ses ve videonun özellik tanımlamasını ve sınıflandırmasını gerçekleştirir.

Şekil 3.4'te gösterildiği üzere evrişim, girdi görüntülerini, her biri görüntülerden belirli özellikleri etkinleştiren bir dizi evrişimsel filtreye yerleştirir. Doğrultulmuş doğrusal birim (ReLU), negatif değerleri sıfıra eşleyerek ve pozitif değerleri koruyarak daha hızlı ve daha etkili eğitim sağlar. Bu bazen aktivasyon olarak adlandırılır, çünkü sadece aktive edilen özellikler sonraki katmana taşınır.

Ortaklama, doğrusal olmayan aşağı örnekleme gerçekleştirerek çıktıyı basitleştirir ve ağın öğrenmesi gereken parametre sayısını azaltır. Bu işlemler onlarca veya yüzlerce katman üzerinde tekrarlanır ve her katman farklı özellikleri tanımlamayı öğrenir.


Evrişim ve ortaklama katmanları yeterli sayıda tekrar edilerek istenilen özellikler giriş verisinden ortaya çıkarılır. Bu özellikler sınıflandırma yapan tam bağlantı ve softmax katmanına aktarılır. Bu yapı Şekil 3.5'te gösterilmektedir.



Şekil 3.5. Çok sayıda evrişimsel katmana sahip bir ağ örneği

Kaynak: (MATLAB, 2020)

3.2.2. Tekrarlayan Sinir Ağları



Şekil 3.6. Tekrarlayan Sinir ağları yapısı

Kaynak: (LeCun, Bengio, and G. Hinton, 2015: 442)

Tekrarlayan sinir ağları (recurrent neural networks-RNN), giriş dizilerini işlemek ve sıralı bilgileri kullanma amaçlı kullanılan sinir ağı türüdür. Bilgilerin hafızada kalmasına yarayan ağlar bu yapının içerisinde vardır.


Bir RNN ünitesinin çıktısının sadece mevcut girdiye değil, aynı zamanda geçmiş bilgiyi taşıyan önceki gizli durumuna da bağlı olduğu görülecektir. Geçmiş öğrenebilir ve ilişkiyi daha iyi anlar. RNN'nin bazı sınırları vardır. Bu sınırları aşmak için 2 farklı mimari çeşidi ortaya çıkmıştır. Bunlar; uzun-kısa vadeli hafıza (Long Short Term Memory-LSTM) ve kapılı tekrarlayan mimarilerdir. LSTM mimarileri metin ve konuşma işleme uygulamalarında, beste uygulamalarında başarılıdır.

Şekil 3.6'da gösterildiği üzere girdiler ve girdilerin geciktirilmiş durumları, tekrarlayan sinir ağlarının girişlerini oluşturmaktadır.

3.3. Klasik P&O Algoritması

Klasik P&O algoritması çoğu yöntemlere göre basit olan ve çok kullanılan bir MPPT yöntemidir. Bu algortmada özellikle panel gerilimi ve akımı ölçülerek ilk durumdaki panel gücü hesaplanmaktadır. Bir sonraki adım olarak gerilimdeki veya yarı iletken anahtarın D değeriindeki değişimleri değerlendirerek gücü yeniden hesaplamaktadır. Ortaya çıkan iki güç değeri farkı sıfır ise algortma başa döner ve yeniden güç hesapları yapmaktadır. Eğer aradaki fark sıfırdan farklı ise bu defa algortma gerilimin değişimine bakmaktadır. İki gerilim değeri farkına göre, doluluk-boşluk oranı olan D oranını değiştirilerek maksimum güç noktası takibi yapılmaktadır.

D&G yöntemi, hızla atmosferik koşullarda sürekli değişim olduğundan parçalı bulutlu havalarda, bazı sapmalar gösterebilmektedir. Bu yöntemde maksimum güç noktası tam olarak izlenememekte ancak maksimum güç noktasına yakın bir yerde salınım yapması sağlanabilmektedir. Klasik P&O akış diyagramı Şekil 3.7’de gösterilmiştir.



Şekil 3.7. Klasik P&O algoritması

4. METOD


Bu tez çalışmasında şebeke bağlantılı bir MPPT sistemi için akım gerilim değerlerinden yararlanarak DC yükseltici doluluk-boşluk oranının yapay zekâ yöntemleri ile kestirilmesi amaçlanmıştır. Bu kestirim ile kullanılan klasik P&O algoritmasından daha iyi verim alınması hedeflenmiştir. Tüm sistem MATLAB/SIMULINK ortamında modellenmiştir.

İzleyen bölümde ilk olarak yapay zeka birimleri için ihtiyaç duyulan eğitim verilerinin nasıl elde edildiği anlatılmıştır. Devamında MATLAB/SIMULINK altında tanımlanan şebeke bağlantılı PV sistemi bileşenleri tanıtılmış ve kullanılan panellere dair genel özellikler sunulmuştur.

4.1. Eğitim Verilerinin Elde Edilmesi


MATLAB/SIMULINK uygulamasında bulunan ve Pierre Giroux, Gilbert Sybille, Carlos Osorio, Shripad Chandrachood tarafından oluşturulan 100 kW gücündeki, 25 kV'luk şebekeye bağlı, DC-DC yükseltici çevirici ve üç fazlı evirici içeren model örnek olarak alınmıştır. Bu modelde 100 kW'lık gücü sağlayan PV panel için 20 ayrı marka panel seçilmiş ve bu panellere ait simülasyonlar yürütülmüştür.

Şekil 4.1'de MATLAB/SIMULINK'ten örnek alınan 100 kW gücündeki şebekeye bağlı PV dizisinin modeli gösterilmektedir. Devamında modele dair bloklar açıklanmıştır.



Şekil 4.1. MATLAB/SIMULINK Sistem Modeli


Kaynak: (MATLAB, 2020)



Şekil 4.2. PV panel dizisi eşdeğer devresi

Kaynak: (MATLAB, 2020)


PV sistemlerinde ortaya konulmuş modellerden biri olan bir-diyot modeli Şekil 4.2’de gösterilmiştir. Bu modelin devre simülasyon programlarıyla simülasyonu yapılabilmektedir. MATLAB/SIMULINK’te örnek alınan 100 kW Şebeke Bağlantılı PV Modeli içerisinde de PV simülasyon modeli bulunmaktadır.



Şekil 4.3. PV panel dizisi Simulink modeli

Kaynak: (MATLAB, 2020)

Şekil 4.3’te panel dizisine ait SIMULINK eşdeğer modeli verilmiş olup, ısıma ve sıcaklığa bağlı olarak bir akım (I_L), buna paralel bir diyot akımı (I_d), kayıp olarak sayılacak paralel ve seri direnç (R_{sh}, R_s) ve bir hücre gerilimi (V) olmak üzere 5 parametrelili bir devreden oluşmaktadır.




Şekil 4.4. DC Yükseltici Çevirici MATLAB/SIMULINK Modeli

Kaynak: (MATLAB, 2020)

Şekil 4.4'te, modelde kullanılan DC yükseltici çeviricinin kendi modeli verilmiş olup, DC gerilimini yükseltmek amaçlı kullanılan bir devre olarak görevini üstlenmiştir. Burada DC-DC çeviricilerin yükselten (boost), alçaltan (buck) ve alçaltan-yükselten (buck-boost) yapıda olabilecekleri belirtilmelidir.

DC-DC dönüştürücüler PV panellerden gelen doğru akımı istenilen doğru akıma ayarlayan güç elektroniği devreleridir. Görevlerini ifa ederken anahtarlama elemanları kullanırlar. Çalışma oranı (D), anahtarın iletimde olma süresinin anahtarlama periyoduna oranıdır. Bir DC-DC dönüştürücüde anahtarın kapalı ve açık kalma oranıyla çıkış gerilim denetimi yapılır. Yükseltici (Boost) DC-DC dönüştürücüler de her zaman giriş gerilimini yükselterek çıkış gerilimi verirler. Giriş çıkış arasındaki oran eşitlik 4.1'de verilmiştir.

$$\frac{V_c}{V_g} = \frac{1}{(1-D)} \quad (4.1)$$



Şekil 4.5. DC-DC Çevirici a) devre şeması ve b) Gerilim dalga

Şekil 4.5'te görüldüğü üzere anahtar kapalı iken ters kutuplanan diyot çıkış tarafından ayırmış olur ve bobine akım sağlanır. Anahtar açıldığında ise girişte bulunan bobindeki akımı çıkışa verir. Böylece çıkış gerilimi hem iletimden aldığı gerilim hem de bobinden gelen gerilim ile birlikte yük tarafına daha yüksek bir gerilim sağlamış olmaktadır. Çıkış geriliminin sabit kalması istenirse çıkıştaki kondansatör büyük olmalıdır.


Yükseltici DC-DC dönüştürücüde anahtar kapalı konumda kalma süresi arttıkça, çıkış gerilimi de artar. Anahtarın çalışma periyodunun referans sinyali ile sabit bir frekansa sahip taşıyıcı sinyali karşılaştırılır ve bu şekilde dönüştürücü anahtarlama ayarı yapılabilmektedir.

$$D = \frac{t_{\text{kapalı}}}{(t_{\text{kapalı}} + t_{\text{açık}})} = \frac{t_{\text{kapalı}}}{T} \quad (4.2)$$

Yukarıdaki denklemde T periyodu, $t_{\text{kapalı}}$ anahtar kapalı olduğu zamanı, $t_{\text{açık}}$ anahtar açık olduğu zamanı belirtmektedir. Anahtarlama yapan güç elektroniği elemanı mosfettir.

Bu tez çalışmasında DC-DC dönüştürücü olarak yükseltici tipte dönüştürücü kullanılmıştır. Örnek alınan “100 kW Şebeke Bağlantılı PV Dizisi” modelinde doluluk-boşluk oranı 0.5'ten başlanmış 0.38-0.58 arasında sınırlandırılmıştır. Bu sınır değerler aynı bırakılmıştır.

Yükseltile DC gerilim üç fazlı eviriciye giriş olarak gönderilir ve eviriciden çıkan gücü Şekil 4.6'da görüldüğü gibi 100-kVA 260V / 25 kV üç fazlı kuplaj transformatörüne bağlayarak 25 kV gerilim değerindeki şebekeye AC güç verilmektedir. Modelde, eviriciler anahtarlama frekansının bir döngüsü boyunca ortalaması alınan AC gerilimini üreten eşdeğer gerilim kaynakları ile temsil edilir.




Şekil 4.6. MATLAB/SIMULINK Şebeke Modeli

Kaynak: (MATLAB, 2020)

Şebeke modelimizde görüldüğü üzere şebekeye verilen 25 kV gerilimli AC güç 5 km ve 14 km uzunluğunda fideri üzerinde 2 MW ve 30 MW gücündeki yüklere enerji sağlamaktadır. Ayrıca şebeke sisteminde, 47 MVA gücündeki trafo merkezinde 2500 MVA gücünde 120 kV gerilim seviyesinde bir üretim tesisinden gelen gerilim indirici merkezinde 120 kV'dan 25 kV şebeke gerilimine düşürülmektedir.

Şekil 4.7'de örnek olarak 1Soltech 1STH-350-WH marka-model panele ait IV ve PV grafik şekillerinde de görüldüğü gibi ışınma miktarının bir PV sistem için önemi çok büyüktür. Kesintisiz maksimum güç noktaları (MPP), maksimum PV verimliliğiyle sonuçlanacak çalışma noktalarını göstermektedir. Sistemin çalışma noktasını bu MPP'ye ne kadar yakın çalışırsa o derece verimlilik oranı yükselmektedir.




Şekil 4.7. 1Soltech 1STH-350-WH marka panele ait marka ve modelin I-V ve P-V eğrileri

Kaynak: (MATLAB, 2020)

Oluşturulan model çalıştırıldığında, klasik P&O algoritmasında ilk D değeri 0.5 alınarak $t=0$ anından $t=0.3$ sn anına kadar, yükseltici çeviricinin doluluk-boşluk oranı değeri sabittir. Elde edilen PV voltajı bu nedenle şöyledir. $V = (1-D) * V_{dc} = (1-0.5) * 500 = 250$ V.

$t = 0.3$ sn anında P&O algoritmasıyla beraber MPPT etkinleştirilmekte, algoritma maksimum gücü elde etmek için D değerini değiştirerek PV voltajını düzenlemektedir. P&O algoritması ilk çevrimini bitirdikten sonra güç değerine göre $3 \cdot 10^{-4}$ adımlarla değiştirerek çalışmasına devam etmektedir. Burada D için sınır değerler $D_{min} = 0.38$, $D_{max} = 0.58$ olarak belirlenmiştir. Sistemin genel çalışmasına dair blok diyagramı Şekil 4.8'de gösterilmektedir.



Şekil 4.8. MPPT kullanan Şebekeye Bağlı Fotovoltaik Sistemin Blok Diyagramı

Tez çalışmasında 20 farklı PV panel seçilmiş olup Tablo 4.1’de kullanılan panel marka-modelleri, sisteme paralel ve seri bağlı panel sayıları, panellerin açık devre gerilimi (V_{oc}), kısa devre akımı (I_{sc}) ile maksimum güç değerleri (P_{max}) ve seri gerilim (V_s), paralel akım değerleri (I_p) gösterilmiştir. Panel seçilirken, P_{max} değerinin 305 W değerinde veya üzerinde olmasına, açık devre geriliminin 64.2 V değerinde veya üzerinde ve kısa devre akımının da 5.96 A değerinde veya üzerinde olan panel marka ve modellerin seçilmesi tercih edilmiştir. Bu şekilde tüm maksimum güç değerlerinin 305 W üstünde olması sağlanmıştır.

Simülasyonlarda mevcut bulunan 100 kW’lık panellerin 100-1000 W/m² ışıma aralığında 100’er artımla ve 0-75 °C sıcaklık aralığında 7.5°C artımla P&O algoritması kullanılarak 2 saniye süresince çalışması sağlanarak panellere dair V-I ve DC yükselticiye dair doluluk-boşluk oranını veren D verileri alınmıştır.

4.2. YSA ile Eğitim Aşaması

YSA ile Tablo 4.1’de verilen marka modellere ait akım-gerilim değerleri giriş olarak alınarak D değeri çıkış olarak verilmektedir.


YSA mimarisi olarak 3 katmanlı 10 x 10 x 1 nöron sayısına sahip ilk iki katmanı tanjant sigmoid, son katmanında lineer aktivasyon fonksiyonu kullanan bir yapı oluşturulmuştur. Bu yapıya dair MATLAB nntool ile oluşturulan yapı şekil 4.9’da gösterilmektedir. Öğrenme algoritması olarak Levenberg-Marquardt algoritması kullanılmıştır. 100-1000 W/m² ışıma ile ve 0-75 °C arasındaki sıcaklıklar için 2 saniyelik V-I ve D verileri kaydedilmiştir. Bu bağlamda (20 x 54609 x 3) boyutlu oluşturulan veri kümesi YSA eğitimi için kullanılmıştır. YSA 428

epokta 0.00626 ortalama karesel hata ile öğrenmeyi gerçekleştirmiştir. Öğrenmenin başarımını gösteren ortalama karesel hataya dair oranlarını vermektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - o_i) \quad \text{f: beklenen değer o: çıkan değer n: örnek sayısı} \quad (4.3)$$


Tablo 4.1. Seçilen PV Panellere Ait Elektriksel Parametreler

	Panel ismi	Voc(V)	Isc(A)	Pmax(W)	Paralel	Seri	Seri gerilim değeri (Vs) Voc*seri	Paralel Akım değeri(Ip) (Isc*paralel)
1	1SOLTech 1STH-350-WH	51,5	9,40	349,59	66,00	7,00	360,50	620,40
2	Yingli Energy (China) YL305P - 35b	46,30	8,87	305,25	66,00	7,00	324,10	585,42
3	Jinko Solar JKM310M-72	47,10	8,78	309,93	66,00	7,00	329,70	579,48
4	Zhejiang Global Photovoltaic Technology GSM-305	44,30	8,69	304,34	66,00	9,00	398,70	573,54
5	China Sunergy (Nanjing) CSUN 320-72M	37,53	8,66	244,93	66,00	10,00	375,30	571,56
6	Trina Solar TSM-315PA14A	46,00	8,86	317,60	66,00	8,00	368,00	584,76
7	Znshine PV-Tech ZXM6-72-330-M	46,72	9,19	330,00	66,00	9,00	420,48	606,54
8	Perlight Solar PLM-350M-80US1	51,50	9,40	349,59	66,00	7,00	360,50	620,40
9	Phono Solar Technology PS320PB-24-T	46,40	8,95	319,68	66,00	8,00	371,20	590,70
10	SOLARTECH ENERGY ASC-6P-72-305	44,96	8,66	304,75	66,00	10,00	449,60	571,56
11	Zhongli Talesun Solar TP672M-310	45,80	8,83	309,96	66,00	10,00	458,00	582,78
12	Renesola America JC305M-24-AB	44,90	8,73	304,88	66,00	9,00	404,10	576,18
13	Renesola Jiangsu JC320S-24-ABH-B	46,10	9,02	320,11	66,00	9,00	414,90	595,32
14	Risen Energy SYP305M	45,00	9,15	305,77	66,00	9,00	405,00	603,90
15	Schuco International MPE 320 MP 02	88,10	4,75	320,76	66,00	10,00	881,00	313,50
16	Semyung Electric SM-T-390-Platinum	61,06	8,77	410,11	66,00	9,00	549,54	578,82
17	Xunlight XR38-307	89,92	6,35	307,15	66,00	8,00	719,36	419,10
18	Shanghai JA Solar Technology JAP6-72-315 MP	45,90	8,84	315,03	66,00	10,00	459,00	583,44
19	Shinsung Solar Energy SS-DM320B3	46,80	9,10	319,92	66,00	8,00	374,40	600,60
20	TATA TP310LBZ	44,60	8,85	309,86	66,00	9,00	401,40	584,10




Şekil 4.9. Kullanılan YSA yapısı

Kaynak: (MATLAB, 2020)



Şekil 4.10. YSA ile D verilerinin eğitilmesi

Kaynak: (MATLAB, 2020)



Şekil 4.11. YSA ile D verilerinin eğitilmesi

Kaynak: (MATLAB, 2020)


Eğitim verilerinin başarılarını göstermek amacıyla şekil 4.10’da gerçek ve YSA’ya dair D verilerinin karşılaştırılması gösterilmiştir. Bu şekilde mavi ile gerçek D verileri, kırmızı ile YSA kestirim değerleri gösterilmektedir. YSA’nın elde ettiği başarım açıkça görülmekte olup, örnek olarak 1Soltech 1STH-350-WH marka-model panel için yakınsama ayrıntılı olarak şekil 4.11’de gösterilmektedir.

4.3. Uzun Kısa Zamanlı Bellek ile eğitim aşaması

LSTM, geleneksel RNN’lerin karşılaştığı kaybolan gradyan problemini ele almaktadır. Bir dizinin gelecekteki zaman adımlarının değerlerini tahmin etmek için, yanıtların bir zaman adımı kaydırılmış değerlere sahip eğitim dizileri olduğu bir diziden diziye geri beslemeli LSTM ağını eğitilebilir. Yani, giriş dizisinin her zaman adımında, LSTM ağı bir sonraki zaman adımının değerini tahmin etmeyi öğrenmektedir. Derin Öğrenme yapıları daha çok sınıflandırma problemlerine odaklandığından yakınsama problemi için uygun yapı olarak RNN ile aynı özelliklerde olan LSTM önerilmektedir.

MATLAB’ta bir arayüz olarak bulunan Deep Network Designer ile derin sinir ağlarının eğitilmesi, gerçekleşmesi ve tasarımı yapılabilmektedir. Buna dair örnek görüntüler şekil 4.12’de gösterilmektedir.

Klasik yapay sinir ağlarının öğrenme algoritması olan en dik iniş (steepest descent) derin sinir ağları için uyarlanmalıdır. En uygun yöntem olarak uyarlanabilir moment tahmini (Adaptive Momentum Estimation-ADAM) algoritması uygulanmaktadır.



Şekil 4.12. Deep Network Designer a) Katman Yapısı b)Özellikleri

Kaynak: (MATLAB, 2020)

ADAM (uyarlanabilir moment tahmini) optimize edici için öğrenme oranı bilgisi, L2 faktörü ve mini-yığın boyutu içeren eğitim algoritmasıdır. Sinir ağlarının eğitim sürecinin başlangıcında en dik iniş yöntemi genellikle yanlış yöne giderken, bu yönteme momentum eklediğimizde olduğu gibi düzeltici etki ile ADAM ile de aynı iyileştirmeyi elde edilir. ADAM algoritmasının zayıflığı olarak veri boyutunun küçük olması durumunda yeterli yakınsamayı sağlayamadığı bilinmektedir.

Yapay sinir ağı eğitimi için oluşturulan veriler LSTM eğitimi için de kullanılmıştır.

Öncelikle verilerin yüklenmesi yapılır ve V-I ve D değerleri zaman serisi de içermektedir. LSTM için 2 giriş tek çıkışlı 80 gizli katmanlı bir mimari seçilmiştir. Ayrıca bu mimari dört katmandan oluşup bunlar sırası ile giriş katmanı (sequenceInputLayer), uzun kısa süreli bellek katmanı (lstmLayer), tam bağlama katmanı (fullyConnectedLayer) ve regresyon katmanıdır.

LSTM için öğrenme seçeneği olarak “ADAM” algoritması seçilmiştir. Gradyan eşliğinin 1, maksimum epok sayısının 250, ilk öğrenme hızı değerinin 0.005 parçalı öğrenme

planı olarak fonksiyon planı, öğrenme hızını 125 epoktan sonra 0.2 faktörüyle çarparak düşürme seçimleri yapılan bir ağ mimarisi ayarlanmıştır.


LSTM Mimarisi doğası gereği giriş ve çıkış eğrilerinin normalize edilmesine ihtiyaç duymaktadır. Bunun için ön işleme adımı olarak MATLAB'ta eğitim verisinin aritmetik ortalaması ve standart sapması hesaplanmaktadır. Eğitim veri setini normalize etmek için eğitim veri seti ile hesaplanan ortalama değerin farkı alınmakta ve bu fark standart sapmaya bölünmektedir. Bu adım eşitlik 4.4'te verilmiştir.

$$X_n = \frac{X - X_{ORT}}{X_{STD}} \quad (4.4)$$

Öğrenme seçenekleri belirlendikten sonra yine MATLAB uygulamasında V-I giriş öğrenme verisinin aritmetik ortalamasını hesaplamaktadır. V-I giriş öğrenme verisinin standart sapmasını da hesaplamaktadır. Daha sonra bu veriyi normalize etmek için V-I giriş öğrenme veri ile hesaplanan ortalama verinin farkı alınmakta ve bu fark değer standart sapmaya bölünmektedir. Bu şekilde V-I giriş öğrenme verisi normalize edilmiştir.

Normalize edilmiş veriler ile elde edilmiş olan LSTM eğitim grafiği şekil 4.13'te verilmiştir. Burada hata değeri RMSE olarak verilmekte olup, RMSE formülü eşitlik 4.5'te verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - o_i)^2} \quad (4.5)$$



Şekil 4.13. LSTM Eğitim ilerleme grafiği

Kaynak: (MATLAB, 2020)

Eđitilmiş olan LSTM ađı kestirim ařamasına gečilerek MATLAB içinde tanımlı olan “predictandUpdateState” işlevi ile ilk kestirim yapılmaktadır. Bundan sonra normalize kestirilmiş veriler daha önceden hesaplanan ortalama deđerler ve standart sapma kullanılarak denormalize edilmiştir. Ve gerçek eğitim verileri ile karşılaştırılmıştır.


Büyük veri dosyaları, uzun diziler veya büyük ađlar için GPU üzerindeki tahminlerin hesaplanması genellikle CPU üzerindeki tahminlerden daha hızlıdır. Bu sebeple bu tip ađların eğitimi için yüksek hesaplama gücüne sahip GPU'lara ihtiyaç duyulmaktadır. Bu tez çalışmasında da LSTM eğitimi için İ3-9100 F işlemci, 16 GB RAM'a ve GT X 1650 SUPER GPU'ya sahip bir masaüstü bilgisayar kullanılmıştır.

Şekil 5.3'te örnek alınan sistemde simülasyon sisteminin sıcaklık grafiği verilmiştir. İlk 2 saniye boyunca 25 °C sıcaklıkta, son 1 saniye ise 50 °C sıcaklık değerinde simülasyon yürütülmüştür.




Şekil 5.3. Sıcaklık Grafiği

Değişken sıcaklık ve gölgeli ve gölgesiz ışımada simülasyon 3 saniye boyunca yürütülmüştür.




Şekil 5.4. Sinir Ağı ile eğitilmiş Ortalama Güç Karşılaştırması

Şekil 5.4'te görüldüğü üzere; sistem ilk 0.3 saniye süresince doluluk-boşluk oranı 0.5 değerinde sabit tutularak çalışmıştır. 0.3 saniyeden itibaren önerilen YSA tabanlı MPPT sisteminin ortalama güç eğrisi olan kırmızı çizgi gerçek değerleri gösteren mavi çizginin üzerinde olduğu zamanlarda daha yüksek ortalama güç sağladığı görülmektedir.



Şekil 5.5. Panel gerilimi karşılaştırması


Şekil 5.5'te 0.9 saniyeden sonra görüldüğü üzere önerilen YSA tabanlı MPPT sisteminin gerilim eğrisi olan kırmızı çizgi gerçek durumu gösteren mavi çizginin altında kalmıştır. Gölgeleme olayı ve sıcaklığın artması gerilimi düşürmektedir. Fakat çok büyük bir veri kümesinin YSA ile eğitimi istenilen düzeyde kestirim yapamamıştır. Her ne kadar ilk 0.9 saniye boyunca kısmen yapabilmiş ise de daha sonra kestirim başarısını kaybetmiştir.



Şekil 5.6. Panel akımı karşılaştırması

Şekil 5.6'da görüldüğü üzere YSA tabanlı MPPT sistemi benzetim sonucundaki panel akımı kırmızı çizgi ile gösterilmiş olup, gerçek durumdaki panel akımı değerini gösteren mavi

çizginin çoğunlukla üstünde bulunduğu görülmektedir. Bu yüzden YSA tabanlı sistemin genellikle gerçekteki sistemden daha iyi bir akım verdiği anlaşılmaktadır.




Şekil 5.7. Sinir Ağı ile eğitilmiş D karşılaştırması

Şekil 5.7’de kırmızı ile gösterilen çizgi önerilen YSA tabanlı MPPT sistemine ait doluluk-boşluk oranı D değeri olup, gerçek olan durumun doluluk-boşluk oranı D mavi ile gösterilmiştir. Sistem ilk 0.3 saniye süresince doluluk-boşluk oranı 0.5 değerinde sabit tutularak çalışmıştır. DC-DC yükseltici çevirici için çok önemli bir parametre olan D değeri simülasyonda da görüldüğü gibi 0.9 saniye civarlarında gerçek değerden uzaklaşmış ve 0.58 değerinde çalışmıştır. Bu da bize YSA ile çok büyük verilerin eğitilmesinin başarımının derecesi konusunda kısmen başarılı olduğunu ancak istenilen seviyede sonuç alınamadığını göstermiştir.

5.2. LSTM ile eğitilmiş veriler ile normal verilerin karşılaştırılması


Şekil 5.8’de MATLAB/SIMULINK’ten örnek alınan ve LSTM metodu ile eğitilmiş verilerin kullanıldığı 100 kW gücündeki şebekeye bağlı PV dizisinin modeli verilmiştir. LSTM ile eğitilmiş verilerin giriş olarak verildiği benzetimde verdiği sonuçlar kaydedilerek grafikler bu kaydedilen sonuçlara göre çizdirilmiştir.



Şekil 5.8. LSTM ile Eğitilmiş MATLAB/SIMULINK Sistem Modeli

Kaynak: (MATLAB, 2020)


Eğitilmiş LSTM verileri simülasyonda P&O MPPT algoritması yerine koyularak yapılan benzetimin sonuçlarına ait grafikler aşağıda verilmiştir.



Şekil 5.9. LSTM Ağı ile eğitilmiş Ortalama Güç Karşılaştırması


Şekil 5.9’da önerilen LSTM tabanlı MPPT sisteminin ortalama güç değeri mavi çizgi ile gerçek durumun ortalama güç değeri kırmızı çizgi ile gösterilmiştir. Mavi çizginin kırmızı

çizgi üzerinde olduğu durumlarda daha iyi güç elde edilmiştir. Mavi çizginin kırmızı çizgi altında kaldığı kısımlarda ise büyük bir güç farkının oluşmadığı görülmektedir. Sadece benzetimin 3. saniyesi olan son saniyesinde bir anda LSTM ağının ortalama güç değerinde beklenmeyen düşme ve hızlı toparlandığı görülmektedir. Sonuç olarak LSTM tabanlı MPPT sistemi başarılı bir ortalama güç değeri vermiştir.




Şekil 5.10. LSTM Ağı ile Eğitilmiş Gerilim Karşılaştırması

Şekil 5.10'da görüldüğü üzere; önerilen LSTM tabanlı MPPT sisteminin gerilim değeri ilk 0.9 saniye boyunca gerçek değer üzerinde kalmış, bu andan itibaren az farkla da olsa gerçek değer altına düşmüştür. Sonuç olarak, LSTM tabanlı sistemin gerilim değerinin gerçek sistem gerilim değeri ile yaklaşık olarak benzer değerlerde kaldığı söylenebilmektedir.



Şekil 5.11. LSTM Ağı ile eğitilmiş Akım Karşılaştırması

Şekil 5.11’de LSTM tabanlı MPPT sistemi benzetim sonucundaki akım mavi çizgi ile gösterilmiş olup, gerçek durumdaki panel akımı değerini gösteren kırmızı çizginin çoğunlukla üstünde bulunduğu görülmektedir. Bu sebeple LSTM tabanlı sistemin genellikle gerçekteki sistemden daha iyi bir akım verdiği anlaşılmaktadır.



Şekil 5.12. LSTM Ağı ile eğitilmiş D Oranı Karşılaştırması


Şekil 5.12’de mavi ile gösterilen çizgi önerilen LSTM tabanlı MPPT sistemine ait doluluk-boşluk oranı D değeri olup, gerçek olan durumun D değeri çıktısı kırmızı ile

gösterilmiştir. Sistem ilk 0.3 saniye süresince doluluk-boşluk oranı 0.5 değerinde sabit tutularak çalışmıştır. DC-DC yükseltici çevirici için çok önemli bir parametre olan D değeri grafikte de görüldüğü gibi ilk saniye civarlarında gerçek değer altında kalmıştır. 0.9 saniyeden itibaren gerçek durumun D değeri 0.38’da kalırken önerilen LSTM tabanlı sistemin değeri yaklaşık 0.44 civarında kalmış ve iyi bir sonuç vermiştir. Bu nedenle önerilen LSTM tabanlı MPPT sisteminin çok büyük verilerin eğitilmesinde ve benzetim çalışmalarında başarılı olduğu görülmüştür.


5.3. LSTM, YSA ve Normal Verilerin Karşılaştırılması

Yukarıda YSA tabanlı MPPT sistemi benzetim sonuçları ile LSTM tabanlı MPPT sistemi benzetim sonuçlarının gerçek değerlerle karşılaştırması ayrı ayrı yapılarak gösterilmiştir.


Sonuçların daha net anlaşılması maksadıyla gerçek değerler, LSTM tabanlı sistem ile YSA tabanlı sisteminin ortalama güç, panel gerilim, panel akımı ve D değerleri her üç sistemin çizgileri birer grafik üzerinde gösterilmek üzere Şekil 5.13 ve devamında verilmiştir.




Şekil 5.13. Ortalama Güç Karşılaştırması



Şekil 5.14. Gerilim Karşılaştırması



Şekil 5.15. Akım Karşılaştırması



Şekil 5.16. D Karşılaştırması

Sonuç olarak yukarıdaki grafikler incelendiğinde; önerilen sistemler ile gerçek sistem ilk 0.3 saniye boyunca D değeri sabit olarak 0.5 değerinde çalışmış ve 0.3 saniye sonrasında önerilen sistemler eğitim aşaması sonucunda oluşturulan D değerinde çalıştırılmıştır. Eğitime koyulan $(20 \times 54609) \times 3$ boyutundaki veri çok büyük bir veri olduğu için YSA ile öğrenimi kısmen başarılı olmuştur. $(20 \times 54609) \times 3$ boyutundaki verinin yine LSTM ile öğrenimi ise başarılı bir sonuç vermiş ve bu başarılı sonuçlar simülasyon grafiklerine de yansımıştır. Grafiklerde LSTM çizgisinde sonlara doğru 2.8 saniyede çökme meydana gelmiştir. İyi bir öğrenmenin gerçekleşmemiş olması bu çökmenin nedeni olarak görülmektedir.

Örnek olarak; 2.5 saniye anında gerçek durumdaki sistemde $D=0.38$ $P=156.69$ kW $I=579.64$ A, $V=270.37$ V değerleri görülmüştür. YSA simülasyonunda $D=0.58$ $P=108.16$ kW $I=603.57$ A, $V=179.205$ V değerleri alınmıştır. LSTM simülasyonunda da $D=0.45$ $P=140.81$ kW $I=592.76$ A, $V=237.56$ V değerleri alınmıştır. D değerinin gerçek, YSA tabanlı ve LSTM tabanlı simülasyonlarının her birinde farklı olması nedeniyle gerilimdeki fark (güç=akım x gerilim) güç farkı olarak ortaya çıkmaktadır.

Bu çalışmada, klasik MPPT yöntemlerinin yerine geçecek YSA ve LSTM tabanlı MPPT algoritmaları ayrı ayrı önerilmiştir. Algoritma arama yapmadan V-I değerlerine bakarak uygun D değerini doğrudan önermektedir. 20 farklı firmaya ait 100 kW.'lık panellerin 100'er artımlı 100-1000 W/m² ışınımında ve 7.5°C artımlı 0-75 °C sıcaklıkta V-I ve D verileri 2 sn. için P&O algoritması yürütülürken kaydedilmiş ve kaydedilen bu veriler iki giriş-tek çıkışlı 3 katmanlı

$10 \times 10 \times 1$ nöronlu YSA'ya öğretilmiştir. $(20 \times 54609) \times 3$ boyutlu veri 428 epokta 0.00626 ortalama karesel hata (MSE) ile öğrenilmiştir. Aynı veriler LSTM ile de 2 giriş-tek çıkışlı 80 gizli katmanlı, ADAM algoritmali bir derin öğrenme metodu ile eğitilmiş $(20 \times 54609) \times 3$ boyutlu veri 250 epokta 0.185 RMSE ile öğrenilmiştir.

LSTM bir derin öğrenme birimi olduğundan YSA'ya göre eğitim aşaması daha uzun sürmektedir. PV sistemler için LSTM tabanlı MPPT sisteminin YSA'dan ve diğer klasik MPPT yöntemlerinden daha iyi sonuçlar vermekte olduğu görülmektedir. Ayrıca örnek olarak alınan model şebeke bağlantılı bir sistem olduğundan şebekeden gelebilecek etkilerin de altında kalabilmektedir.

Bu çalışma ile PV sistemlerde derin öğrenme kullanılarak tasarlanan yapay zeka tabanlı MPPT sistemlerinin klasik MPPT algoritmalarına göre daha verimli bir güç elde edildiği ve bu alanda yapılacak çalışmalara da rehber olabileceği düşünülmektedir. Gelecek çalışmalarda önerilen sistemlerin gerçek bir şebeke bağlantılı MPPT sistem üzerinde denenmesi hedeflenmektedir.

KAYNAKÇA

Albayrak, B. (2011). *Elektrik Enerjisi Üretiminde Yenilenebilir Enerji Kaynakları Ve Finansmanı: Bir Uygulama*, Kadir Has Üniversitesi Sosyal Bilimler Enstitüsü. İstanbul.(Doktora Tezi).

Anzalchi, A., & Sarwat, A. (2017). Overview of technical specifications for grid-connected photovoltaic systems. *Energy Conversion and Management*, 152, 312–327.

Ardıç, O. (2015). *Güneş Panellerinde Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Yöntemi ile Maksimum Güç Noktası Takibi*, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü Afyon.(Yüksek Lisans Tezi).

Aydoğan, D. (2019). *PSO Tabanlı Maksimum Güç Noktası Takip Algoritmasının Geliştirilmesi Ve Uygulanması*, Nevşehir Hacı Bektaş Veli Üniversitesi, Fen Bilimleri Enstitüsü, Nevşehir (Yüksek Lisans Tezi).

Bakım, S. (2016). *Yeni Bir P&O Tabanlı MPPT Algoritması Tasarımı Ve Performansının Testi*, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Afyonkarahisar (Yüksek Lisans Tezi).

Baçoğlu, M. E. (2017). *Fotovoltaik Sistemler İçin Yeni Bir Maksimum Güç Noktası İzleme Yönteminin Geliştirilmesi Ve Uygulanması*, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli. (Doktora Tezi).

Çakmak, R. (2012). *Fotovoltaik Güç Üretim Sistemleri İçin Bulanık Mantık Tabanlı Maksimum Güç Noktası Takip Sistemi*, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon. (Yüksek Lisans Tezi).

Çelik, Ö. (2015). *A Novel Hybrid MPPT Method For Grid Connected Photovoltaic Systems With Partial Shading Conditions*, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana. (Yüksek Lisans Tezi).

Çetinbaş, İ. (2014). *Güneş Enerjili Sistemlerde Kullanılan Maksimum Güç Noktası Takibi Yöntemlerinin Zeki Algoritmalar Yardımıyla Uygulanması*, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük. (Yüksek Lisans Tezi).

Deng, L., & YU, D. (2013). Foundations and Trends in Signal Processing, *Deep Learning: Methods and Applications*. 7(3-4), 197–387.

Erdoğan, S. D. (2011). *Fotovoltaik Sistemlerde Yapay Sinir Ağları ile Maksimum Güç Noktası İzleyicisi Tasarımı*, Ege Üniversitesi, Fen Bilimleri Enstitüsü, İzmir. (Yüksek Lisans Tezi).

İleri, K. (2017). *Sürücü Güvenliği İçin Gerçek Zamanlı Şeritten Ayrılma ve YSA Tabanlı Önden Çarpma Uyarı Sistemi*, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük. (Yüksek lisans tezi).

Işık, R. (2015). *Fotovoltaik Dizilerin Kısmi Gölgelemesi Durumunda Maksimum Güç Noktası Takibi Yapabilen Bir Algoritmanın Geliştirilmesi*, Harran Üniversitesi, Fen Bilimleri Enstitüsü, Şanlıurfa (Yüksek Lisans Tezi).

Işık, E., Esener, İ. (2012). *Akıllı Sistemler Kullanılarak Güç Sistemlerinde Yük Tahmini Analizi Ve Uygulanması*, Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik. (Yüksek Lisans Tezi).

Jordehi, A. (2016), Maximum power point tracking in photovoltaic (PV) systems: A review of different approaches. *Renewable and Sustainable Energy Reviews*, 65, 1127-1138.

Joshi, P., & Arora, S. (2016). Maximum power point tracking methodologies for solar PV systems – A review. *Renewable and Sustainable Energy Reviews*. 70, 1154-1177.

Keskin, T. (2019). *MPPT Algoritmalarının Gerçek Zamanlı Olarak Karşılaştırılması ve PV Sistemine Uygulanması*, Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Isparta (Yüksek Lisans Tezi).

Kulaksız, A. A. (2007). *Maksimum Güç İzleyicili ve UVM İnverterli Fotovoltaik Sistemin Yapay Sinir Ağları Tabanlı Kontrolü*. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya. (Doktora Tezi).

Kutlu, B., & Badur, B., (2009). Yapay Sinir Ağları ile Borsa Endeksi Tahmini, İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Dergisi, Haziran 2009, Sayı 63, ss. 25-40.

LeCun, Yann & Bengio, Y. & Hinton, Geoffrey. (2015). Deep Learning, *Nature*, 521, 436-44.

Madi, F. (2018). *Maximum Power Point Tracking Using Firefly Algorithm For Solar Photovoltaic Systems*. Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük. (Yüksek Lisans Tezi).

Özcan, T. (2020). *Derin Öğrenme İle İnsan Edimlerinin Tanınması*, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri (Yüksek Lisans Tezi).

Ram, J., Babu, T., & Rajasekar, N. (2017). A comprehensive review on solar PV maximum power point tracking techniques. *Renewable and Sustainable Energy Reviews*. 67, 826-847.

Ramli, M., Twaha, S., Ishaque, K., & Al-Turki, Y. (2016). A review on maximum power point tracking for photovoltaic systems. *Renewable and Sustainable Energy Reviews*. 67, 144-159.

Soylu, E. (2016). *Bataryaların Kondisyonlarını İzleyerek Yapay Sinir Ağları ile Batarya Türü ve Şarj Durumu Tahmini*, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük. (Yüksek lisans tezi).

Süzen A.A., Kayaalp K., 2018, *Derin Öğrenme ve Türkiye’de ki Uygulamaları*, IKSAD Yayınevi, Türkiye, ISBN: 978-605-7510-53-2 .

Şeker, A., Diri, B., & Balı, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3 (3), 47-64.

Tüysüz, M. (2018). *Hibrit Güç Sistemlerinde Maksimum Güç Noktası Takibi İçin Bulanık Denetleyicinin Optimizasyonu*, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon. (Yüksek Lisans Tezi).

Yavuz, E. (2020). *Konutlarda Enerji Tüketimi Kestirimi İçin Derin Öğrenme ve Makine Öğrenme Yöntemlerinin Karşılaştırılması*. İstanbul Üniversitesi-Cerrahpaşa, Lisansüstü Eğitim Enstitüsü, İstanbul. (Yüksek Lisans Tezi).

Zafari, A., Kianmehr, M.H. & Abdolazadeh, R. (2013). Modeling the effect of extrusion parameters on density of biomass pellet using artificial neural network. *Int J Recycl Org Waste Agricult* 2, 9.

ÖZGEÇMİŞ

Kişisel Bilgiler



Adı Soyadı : Halil İbrahim TEMEL

Doğum Yeri ve Yılı : Batman / 1991

ORCID : 0000-0002-2497-4665

Eğitim Durumu

Lisans Öğrenimi : Karabük Üniversitesi, Elektrik-Elektronik Mühendisliği (İngilizce)

Bildiği Yabancı Diller : İngilizce

İş Deneyimi

Çalıştığı Kurumlar : Demiryürek Elektrik A.Ş., Begel Enerji Ltd. Şti.

İletişim

e-posta : temelhalil72@gmail.com