



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 27.10.2022
Kabul Tarihi : 01.12.2022

Received Date : 27.10.2022
Accepted Date : 01.12.2022

KISMİ GÖLGELENME KOŞULLARINDAKİ FV SİSTEMLERİN DERİN ÖĞRENME TABANLI MAKSİMUM GÜÇ NOKTASI TAHMİNİ

DEEP-LEARNING BASED MAXIMUM POWER POINT PREDICTION FOR A PV SYSTEM UNDER PARTIAL SHADING CONDITIONS

Ramazan AKDERE^{1*} (ORCID: 0000-0002-2756-3474)
*Erdal KILIÇ*¹ (ORCID: 0000-0002-1572-6109)
*Ö. Fatih KEÇECİOĞLU*¹ (ORCID: 0000-0001-7004-4947)

¹ Kahramanmaraş Sütçü İmam Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Ramazan AKDERE, akdereramazan@gmail.com

ÖZET

Bu çalışmada, kısmi gölgeleme koşulları (KGK) altındaki bir fotovoltaik (FV) sistemin, maksimum güç noktası (MGN) derin öğrenme yöntemi kullanılarak tahmin edilmiştir. Çalışmada kullanılacak veri seti Matlab/Simulink ortamında FV sistem modellenerek oluşturulmuştur. Bu veriler kullanılarak derin öğrenme ağının farklı katman sayısı ve nöron sayısı için başarısı incelenmiştir. Model başarısı ortalama mutlak yüzde hata (MAPE), ortalama mutlak hata (MAE), ortalama hata karekökü (RMSE) istatistiksel performans kriterleri ile değerlendirilmiştir. Çalışma sonucunda elde edilen tablo ve grafiklerden eğitim setindeki üç katmanlı ve 64 nöronlu sistemin daha başarılı sonuçlar verdiği gözlemlenmiştir.

Anahtar Kelimeler: Fotovoltaik, kısmi gölgeleme koşulları, derin öğrenme.

ABSTRACT

In this study, the maximum power point is estimated using deep learning method for a photovoltaic (PV) system under partial shading conditions. The data set to be used in the study is created by modeling the PV system in Matlab/Simulink environment. The success of the deep learning network is examined for different number of layers and number of neurons using these data. Model success is evaluated with mean absolute percent error (MAPE), mean absolute error (MAE), root mean square error (RMSE) statistical evaluation criteria. From the tables and graphics obtained as a result of the study, it is observed that the three-layers and 64-neurons system in the training set gives more successful results.

Keywords: Photovoltaic, partial shading conditions, deep learning.

GİRİŞ

Dünyamızda enerji kaynağı olarak en çok fosil yakıtlar kullanılmaktadır. Fiyatının yüksek olması, kaynakların sınırlı olması ve çevre kirliliğine yol açması gibi birçok sorunu bulunması nedeniyle alternatif enerji kaynak arayışlarını artırmıştır (Keçecioglu vd., 2015; Kılıç, 2019). Güneşten dünyamıza bir dakikada ulaşan enerji miktarı dünyanın bir yılda kullandığı enerjiden fazladır. Böylesine büyük ve temiz bir enerji kaynağının kullanılabilmesi için yapılan çalışmalar hız kazanmıştır. Ülkeler çevreye zarar veren enerji kaynaklarından uzaklaşmakta ve yenilenebilir enerjiye geçmek için araştırmalar yapmaktadır. Böylece güneş enerjisinin kullanımı her geçen gün artmaktadır. Güneş enerjisinden elektrik üretimi genellikle ışığı doğrudan elektrige çeviren FV sistemlerle yapılmaktadır. Güneş enerjisinden elektrik üretimi her geçen gün teknolojik olarak ilerlemekte, maliyet bakımından düşüş göstermektedir. Temiz bir enerji kaynağı olmasının yanı sıra kurulumdan sonra düşük maliyetle çalışması gibi nedenlerden dolayı güneş enerjisinin önemi her geçen gün artmaktadır (EİGM, 2021). FV sistemler, tarımsal işletme, endüstriyel işletme, alışveriş merkezi, spor tesisi, konut enerji santrali gibi birçok yerde ihtiyaç duyulan enerjinin bir kısmının veya tamamının karşılanması için kullanılabilir. Ayrıca enerji üretilerek dağıtım şirketlerine satılabilir (Balkan, 2022).

FV hücreler daha büyük akım, gerilim ve güç değerleri elde edilmesi için seri, paralel ve seri-paralel bağlanarak FV panel oluşturulur. FV paneller seri, paralel ve seri-paralel bağlanarak FV dizi oluşturulur. Benzer koşullarda FV paneller ve diziler, FV hücrelerin karakteristik eğrisine sahiptir. Farkları ise çıkışta elde edilen akım, gerilim ve güç değerleridir (Özcelik, 2015).

Şehir merkezleri başta olmak üzere FV sistemlerin kurulumunda dikkat edilmesi gereken bazı önemli noktalar vardır. FV panellerin kurulumdan önce gölge ve verim analizlerinin çok iyi yapılması gerekmektedir (Eltez, 2022). Güneş panellerinin üzerine bulut, bina ya da ağaç gölgesi düşmesi, tozlanma gibi nedenlerden dolayı FV panellerin çıkış güçlerinde azalmalar meydana gelir. Bu duruma kısmi gölgelenme koşulu denilmektedir. Panellerin bazı hücrelerinin maksimum verim ile global maksimum güç noktasında (GMGN) çalışırken bazı hücrelerin KGK altında çalışması panel çıkış gücünün yerel maksimum güç noktası (YMGN) ile çalışmasına sebep olabilir. Bu da sistemden elde edilebilecek verimin düşmesine neden olur. Sistemin GMGN çalışmasını sağlamak için değiştir & gözle, artan iletkenlik, kısa devre akımı, açık devre gerilimi gibi maksimum güç izleme algoritmaları kullanılmaktadır. Klasik bu algoritmaların yanı sıra yapay sinir ağları (YSA), parçacık sürü optimizasyonu (PSO), bulanık mantık, ateş böceği algoritması (ABA), guguk kuşu arama algoritması (GKAA) vb. akıllı algoritmalar da geliştirilmiştir (Karakaya, 2021).

FV çıkış gücü tahmini son yirmi yılda birçok araştırmacı ve akademisyenin dikkatini çekmektedir (Mellit vd., 2014). Son dönemlerde süper bilgisayarların da ortaya çıkması sonucunda dünya çapında toplanan büyük miktarda verinin işlenebilmesiyle birlikte birçok araştırmacı tahmin doğruluğunu artırmak için derin öğrenme uygulamaları geliştirmektedir (Mellit vd., 2020).


Bu çalışmada, FV sistemlerde KGK altında bulunan 4 adet FV panel seri olarak bağlanmış ve giriş ışınım değerleri (G) (W/m^2), 100'er aralıkla değiştirilerek 10000 adet giriş verisi elde edilmiştir. MATLAB/Simulink ortamında yapılan model ile bu giriş verilerine karşılık gelen 10000 adet çıkış verisi bulunmuştur. Oluşturulan bu veri seti içerisinde 7000 veri öğrenme için, 1500 veri doğrulama için, 1500 veri de test için ayrılmıştır. Ayrılan bu verilerin yapılan tüm çalışma boyunca aynı kalması sağlanarak araştırma sonucunun ortaya çıkabilecek hatalardan arındırılması amaçlanmıştır. Elde edilen veriler derin öğrenme ile her katmanda bulunan nöron sayısı için üç defa eğitilmiştir. Eğitim sonucunda katman sayısının ve nöron sayısının değiştirilmesi durumunda çıkış güçlerinde meydana gelen farklılıkların incelenmesi için MAPE, MAE ve RMSE istatistiksel değerlendirme yöntemleri ile her katmandaki tüm nöron sayıları için yapılan üç eğitimin ortalaması alınmış ve bulunan sonuçlar karşılaştırılmıştır. Yapılan bu çalışmada, daha önceki çalışmalardan farklı olarak eğitim tamamladıktan sonra eğitim setine dâhil olmayan ve ara değerlerden oluşan toplam 100 adet veri ile derin öğrenme modelleri teste tabi tutulmuştur. Ayrıca birçok istatistiksel değerlendirme kriteri ile karşılaştırma yapılarak elde edilen sonuçların tutarlılığı çok daha net bir şekilde ortaya konulmuştur.

Bu çalışmanın ikinci bölümünde fotovoltaik sistemlerde maksimum güç noktası, kısmi gölgelenme koşulları ifade edilmiş, üçüncü bölümünde derin öğrenme yöntemi ve veri seti açıklanmış, dördüncü bölümde istatistiksel değerlendirme kriterleri belirtilmiş, beşinci bölümde çalışmadan elde edilen bulgular detaylı olarak incelenmiş ve son bölümde çalışmanın sonuçlarına yer verilmiştir.

FOTOVOLTAİK SİSTEMLERDE KISMİ GÖLGELENME KOŞULLARI

FV panellerin düzgün güneş ışınımı dağılımındaki bağlantısı Şekil 1. a'da gösterilmiştir. KGK altında FV panellerin güçleri farklılıklar gösterir. Şekil 1.b'de kısmi gölgeleme koşulları altında FV paneller gösterilmiştir. Bu durum sistemden maksimum verim alınmasını engeller. Bu güç farklılıkları dolayısıyla YMGN ortaya çıkar. Maksimum güç noktası takibi (MGNT) teknikleri ile bu FV panellerin GMGN'da çalışması amaçlanır. Yapay zekâ, GMGN elde etmek için kullanılan ve oldukça etkili olan bir yöntemdir (Bassam, 2018; Karakaya, 2021). Düzgün dağılım koşulları altında FV paneller maksimum verim ile çalışırlar. Böylece tüm panellerden o anki ışınım değerine bağlı olarak GMGN'de verim elde edilir. Panellerin bir kısmında KGK oluşması durumunda bu panellerden alınan güçte azalma meydana gelir. KGK altında çalışan paneller YMGN'de çalışır ve verim düşer. Şekil 2'de FV panellerin güç gerilim eğrisi gösterilmiştir (Keskin, 2014; Qassab, 2015). Işık şiddetinin akım-gerilim karakteristiğinde akımı, güç-gerilim karakteristiğinde gücü artırdığı anlaşılmaktadır (Özçalık vd., 2013).

Bu çalışmada, 300 W_p gücünde 4 adet FV panel seri olarak bağlanmıştır. Yapılan çalışma ile KGK altında bulunan FV paneller MATLAB/Simulink ile modellenmiştir. Tablo 1'de çalışmada kullanılan FV panelin elektriksel parametre ve değerleri verilmiştir. Tablo 2'de FV panel modeli parametre ve değerleri verilmiştir.



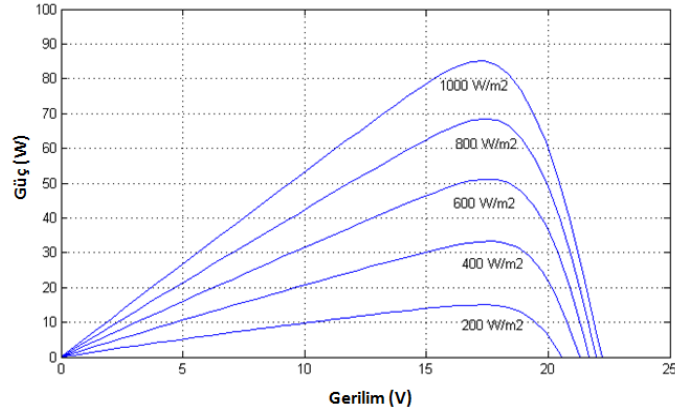
Şekil 1. a. Düzgün Dağılım Altında FV Paneller b. KGK Altında FV Paneller

Tablo 1. FV Panel Elektriksel Parametre ve Değerleri

Parametre	Değer
Güç (W)	300
G : Güç Yoğunluğu (W/m ²)	152,9
I _{mp} : Maksimum Güçteki Akım (A)	8,14
V _{mp} : Maksimum Güçteki Gerilim (V)	36,9
I _{sc} : Kısa Devre Akımı (A)	8,67
V _{oc} : Açık Devre Gerilimi (V)	45
Nominal Çalışmada Hücre Sıcaklığı (°C)	45
Açık Devre Gerilimi Sıcaklık Sabiti (%/°C)	-0,42791
Kısa Devre Akımı Sıcaklık Sabiti (%/°C)	0,086701
Panel Verimi (η)	%15.5


Tablo 2. FV Panel Modeli Parametre ve Değerleri

Parametre	Değer
I _L : Işıktan Üretilen Akım (A)	8,6751
I ₀ : Diyot Doyum Akımı (A)	2,6018x10 ⁻⁹
Diyot İdealite Faktörü	1,1098
R _{SH} : Paralel Direnç (ohm)	665,1993
R _s : Seri Direnç (ohm)	0,26603





Şekil 2. FV Panellerin Güç-Gerilim Eğrisi

Yapılan çalışmada eğitim veri seti içerisinde bulunan $G1=100 \text{ W/m}^2$, $G2=200 \text{ W/m}^2$, $G3=300 \text{ W/m}^2$ ve $G4=400 \text{ W/m}^2$ olduğu duruma ait YMGN ve GMGN değerlerini gösteren akım (A) – gerilim (V), güç (W) – gerilim (V) grafikleri aşağıdaki Şekil 3’te verilmiştir. $G1=600 \text{ W/m}^2$, $G2=500 \text{ W/m}^2$, $G3=100 \text{ W/m}^2$, $G4=300 \text{ W/m}^2$ giriş değerlerine karşılık gelen YMGN ve GMGN değerleri ile akım (A) – gerilim (V), güç (W) – gerilim (V) grafikleri Şekil 4’de gösterilmiştir.



Şekil 3. 100- 200-300-400 Veri Girişine Karşılık Gelen a. Akım-Gerilim Grafiği b. Gerilim-Güç Grafiği

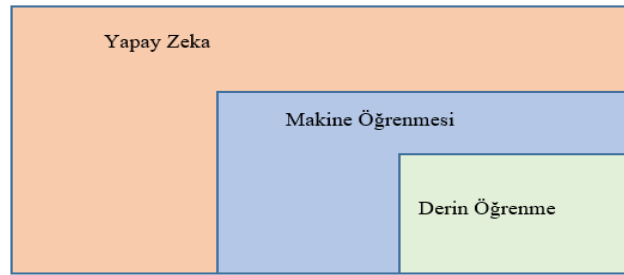




Şekil 4. 600- 500-100-300 Veri Girişine Karşılık Gelen a. Akım-Gerilim b. Gerilim-Güç Grafiği

DERİN ÖĞRENME

Derin öğrenme, özellikleri ve görevleri doğrudan verilerden öğrenen, farklı veriler için sonuçları tahmin etmeye yarayan bir makine öğrenme yöntemidir (LeCun vd., 2015). Derin öğrenme kavramı (yani birden fazla gizli katmana sahip sinir ağları), ana özelliğinin hiyerarşik olarak birçok doğrusal olmayan bilgi işleme katmanını kullanmak olduğu geniş bir makine öğrenimi yaklaşımları ve mimarileri sınıfı olarak düşünülebilir (Yousefi-Azar & Hamey, 2017). Derin Öğrenme, YSA tekniklerinin ve algoritmalarının eğitim için kullanıldığı bir makine öğrenimi dahıdır (Alaskar & Saba, 2021). Derin öğrenme denetimli, yarı denetimli veya denetimsiz olarak gerçekleştirilebilir (Schmidhuber, 2015; Can, 2020). Şekil 5'te yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki gösterilmiştir.



Şekil 5. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme.

Makine öğreniminin bir alt kümesi olan derin öğrenme, yapılandırılmamış veriler üzerinde çok daha iyi başarı sağlayan bir öğrenim sınıfıdır. Derin öğrenme, özellik çıkarma ve dönüştürme için çok sayıda doğrusal olmayan işlem birimi katmanı kullanır. Derin öğrenme ağı içerisinde bulunan veri girişine yakın alt katmanlar, basit özellikleri öğrenirken üst katmanlar ise alt katman özelliklerinden türetilen daha karmaşık özellikleri öğrenir. Büyük miktardaki verileri kullanıp gerekli bilgileri analiz ederek çıkarım yapabilmesini sağlayan bu yapı derin öğrenmeyi diğer öğrenme yöntemlerine göre daha üstün kılmaktadır (Shinde & Shah, 2018; Mathew vd., 2020). Derin öğrenmede en önemli konulardan birisi veri setinin yeterli olmasıdır. Eğitimin başarılı olabilmesi için veri sayısının çok olması gerekmektedir. Eğer eğitimde kullanılan veri sayısı yeterli düzeyde olmazsa ağın öğrenmesi zorlaşacaktır (Can, 2020).

Yapılan çalışmada 300 Wp gücündeki güneş panellerinden 4 tanesi seri bağlanmış ve FV panelin giriş ışınım değerleri (W/m^2), 100 ve katları şeklinde değiştirilerek çıkışta elde edilen toplam gücün değeri bulunmuştur. Toplam 10000 veri elde edilmiştir. Ayrıca eğitime hiç girmemiş ve ara değerlerden oluşan 100 adet veri seti performans testi için oluşturulmuştur. Veri setinin bir parçası Tablo 3'te gösterilmiştir.


Tablo 3. Eğitimde Kullanılan Veri Seti Örneği

	G1(W/m ²)	G2(W/m ²)	G3(W/m ²)	G4(W/m ²)	ÇIKIŞ(W)
1	100	100	100	100	111,163
2	100	100	100	200	116,317
3	100	100	100	300	117,464
4	100	100	100	400	118,121
5	100	100	100	500	140,207
6	100	100	100	600	168,995
7	100	100	100	700	197,707
8	100	100	100	800	226,301
9	100	100	100	900	254,75
10	100	100	100	1000	283,028
11	100	100	200	100	116,304
12	100	100	200	200	122,094
...
9999	1000	1000	1000	900	1143,872
10000	1000	1000	1000	1000	1201,053

Bu veri setinin %70'i (7000 veri) eğitim için, %15'i (1500 veri) doğrulama için, %15'i (1500 veri) test için kullanılmıştır. Bu verilere ait giriş ve çıkış bilgileri kullanılarak derin öğrenme ağı eğitilmiştir. Çalışmada katman ve nöron sayıları değiştirilerek istatistiksel değerlendirme kriterleri olan MAPE, MAE ve RMSE ile en iyi sonucun hangi katman sayısında ve nöron sayısında elde edileceği incelenmiştir.

Yapılan çalışmanın, eğitim veri setinde hiç olmayan ve ara değerlerden (Ör: 170W/m², 915W/m²) oluşan 100 adet veri ile test edilmesi amaçlanmıştır. Eğitim veri setinde bulunan 7000 verinin sürekli eğitim setinde olması, doğrulama veri setinde bulunan 1500 verinin sürekli doğrulama veri setinde olması ve test veri setinde bulunan 1500 verinin sürekli test veri setinde olması sağlanarak sonuçların tutarlı olması ve hatanın en aza indirilmesi amaçlanmıştır. Çalışma sonucunda ortaya çıkan eğitim ve test değerleri tablolar ve grafikler ile gösterilmiştir.

Elde edilen sonuçların derin öğrenme ile FV sistemlerin eğitilmesi durumunda KGK altında verimlerinin artırılacağı ortaya konulmuştur. Derin öğrenme modelinin tahmin sürecine ilişkin tasarım aşamalı olarak gerçekleştirilmiştir. Eğitimde kullanılan derin öğrenme modeline ait mimari Şekil 6'da gösterilmiştir. k değeri (nöron sayısı) 16, 32, 64, 128, 256 ve 512 olarak alınmıştır.

**Şekil 6.** Eğitimde Kullanılan Derin Öğrenme Modeli Mimarisi

İSTATİSTİKSEL DEĞERLENDİRME KRİTERLERİ

Derin öğrenme ile yapılan çalışmalarda, uygulanan modelin performansını değerlendirmek için MAPE, MAE, RMSE istatistiksel değerlendirme kriterleri esas alınmıştır. Regresyon ve zaman serileri modellerinde tahmin sonuçlarının doğruluğunu ölçmek için MAPE çok sık kullanılmaktadır. Gerçek değerlerin arasında sıfır bulunanlar olması durumunda, sıfır ile bölünme yapılamayacağından MAPE değeri hesaplanamaz. Çok düşük tahmin değerleri için yüzde hatası %100'ü geçemez. Ancak tahmin değerlerinin çok yüksek olduğu durumda yüzde hatasının üst sınırı yoktur. Eşitlik 1'de MAPE istatistiksel değerlendirme ölçütü verilmiştir.

$$MAPE = 100 \times \frac{\sum_{i=1}^n \left| \frac{g_i - t_i}{g_i} \right|}{n} \quad (1)$$

g_i : i-inci birimin gerçek değeri
 t_i : i-inci birimin tahmin edilen değeri
 n : Toplam veri sayısı

Literatürde yapılan çalışmalarda; MAPE (%) değerinin, %10'un altındaki modellerin "çok iyi", %10 ile %20 arasındaki modellerin "iyi", %20 ile %50 arasında olan modellerin "kabul edilebilir" ve %50'nin üzerinde olan modellerin ise "yanlış ve hatalı" olarak sınıflandırıldığı değerlendirilmektedir (Lewis Colin, 1982; Witt & Witt, 1992).

MAE, ortalama mutlak hata iki sürekli değişken arasındaki farkın ölçüsü olarak tanımlanır. MAE, her gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir. Bunun yanı sıra MAE, her veri noktası ile en iyi uyan çizgi arasındaki ortalama yatay mesafedir. MAE değeri kolay yorumlanabilir bir değerdir. Bundan dolayı regresyon ve zaman serisi problemlerinde çoğunlukla kullanılmaktadır. MAE, yönlerine dikkat etmeksizin bir dizi tahmin sonucundaki hataların ortalama büyüklüğünü ölçen ve tüm tekil hataların ortalama eşit olarak ağırlıklandırıldığı doğrusal bir skordur. MAE değeri 0 ile ∞ arasında değer alabilir. Puanların negatif yönelimli olması tahminleyicinin daha iyi bir performans gösterdiğinin işaretidir. Eşitlik 2'de MAE istatistiksel değerlendirme ölçütü verilmiştir (Gültepe, 2019).

$$MAE = \frac{1}{n} \sum_{i=1}^n |g_i - t_i| \quad (2)$$

g_i : i-inci birimin gerçek değeri
 t_i : i-inci birimin tahmin edilen değeri
 n : Toplam veri sayısı

Diğer bir performans değerlendirme ölçütü ise RMSE'dir. RMSE; tahminleyici tarafından tahmin edilen değer ile gerçek değer arasındaki uzaklığın bulunması için çoğunlukla kullanılan, hatanın büyüklüğünü ölçmek için kuadratik bir metriktir. RMSE tahmin hatalarının (kalıntıların) standart sapmasıdır. Tahmin hataları, regresyon hattının veri noktalarından ne kadar uzakta olduğunun bir ölçüsüdür; RMSE ise bu kalıntıların ne kadar yayıldığını gösteren bir ölçüdür. Özetle RMSE, verilere en iyi uyan çizgi etrafındaki o verilerin ne kadar yoğun olduğunu gösterir. RMSE değeri 0 ile ∞ arasında değer alır. Değerlerin negatif yönelimli olması yani değerinin düşük olması daha iyi bir performansa sahip olduğunu gösterir. RMSE değerinin sıfıra eşit olması uygulanan modelde hiç hata olmadığı anlamına gelir. RMSE, büyük hataları daha fazla cezalandırmanın avantajına sahiptir. Bu yüzden bazı durumlarda kullanılması daha uygun olabilir. Eşitlik 3'te RMSE istatistiksel değerlendirme ölçütü verilmiştir (DANDIL & Gürgen, 2019).

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (g_i - t_i)^2}{n}} \quad (3)$$

g_i : i-inci birimin gerçek değeri
 t_i : i-inci birimin tahmin edilen değeri
 n : Toplam veri sayısı

R^2 değeri, verilerin doğrusal bir eğriye uygunluk ölçütünü gösterir. 0 ile 1 arasında değer alır. 0'a yakın olması durumunda veriler arasındaki ilişki düşük iken, 1'e yakın olması durumunda veriler arasındaki ilişki kuvvetli

demektir. R^2 değerinin 1 olması veriler arasında kusursuz bir ilişki olduğunu gösterir. Veri sayısının çok olması R^2 değerinin güvenilirliğini artırır.

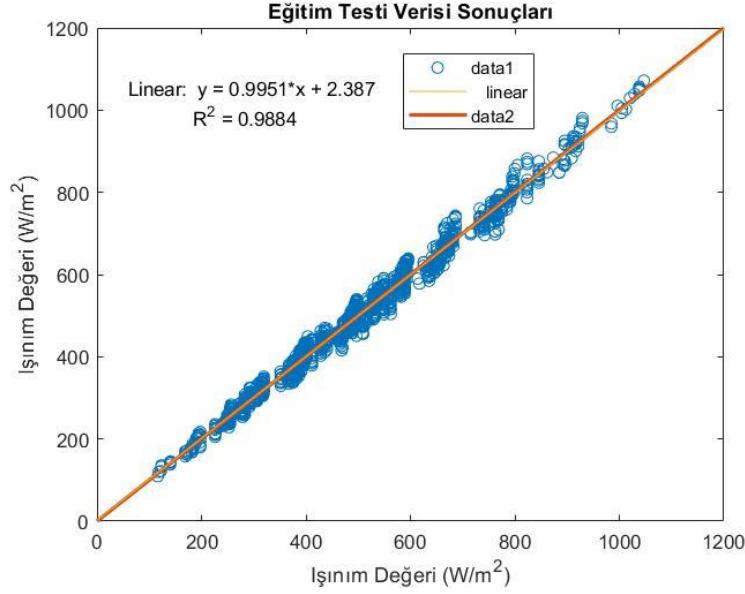
Tablo 4. Eğitim Test Setine Ait 2 Katmanlı ve 16 Nöronlu Sonuçlar

	1. EĞİTİM	2. EĞİTİM	3. EĞİTİM	ORTALAMA
RMSE (kW)	0,027	0,024	0,025	0,025
MAE (kW)	0,021	0,019	0,019	0,020
MAPE	4,370	3,993	4,171	4,178
R^2	0,979	0,981	0,983	0,981
Zaman	2 Dakika 4 Saniye	2 Dakika 5 Saniye	2 Dakika 4 Saniye	2 Dakika 4 Saniye

Tablo 5. Tek Katmanlı Eğitim Test Seti Verilerine Ait Değerler

	16 NÖRON	32 NÖRON	64 NÖRON	128 NÖRON	256 NÖRON	512 NÖRON
RMSE (kW)	0,041	0,032	0,023	0,022	0,019	0,024
MAE (kW)	0,032	0,025	0,019	0,018	0,015	0,019
MAPE	6,749	5,362	3,990	3,730	3,135	4,012
R^2	0,946	0,968	0,984	0,986	0,989	0,987
Zaman	1 Dakika 51 Saniye	1 Dakika 52 Saniye	1 Dakika 53 Saniye	1 Dakika 53 Saniye	2 Dakika 1 Saniye	2 Dakika 4 Saniye

Tablo 4'te eğitim test setine ait 2 katmanlı ve 16 nöronlu yapıya ilişkin sonuçlar örnek olarak gösterilmiştir. Tek katman kullanılarak yapılan eğitim sonucunda Tablo 5'te gösterilen değerler elde edilmiştir. Tek katmanlı eğitim test seti verilerine ait tablo incelendiğinde tek katman kullanılarak 16 nöronlu yapıda ortalama MAPE değerinin ortalama %6,74, 32 nöronlu yapıda ortalama MAPE değerinin %5,36, 64 nöronlu yapıda ortalama MAPE değerinin %3,99, 128 nöronlu yapıda ortalama MAPE değerinin %3,73, 256 nöronlu yapıda ortalama MAPE değerinin %3,13, 512 nöronlu yapıda ortalama MAPE değerinin %4,01 olduğu görülmektedir. Bu değerler %10'dan küçük olduğundan eğitim başarısının çok yüksek olduğu görülmektedir. Eğitim verileri içerisinde tek katman kullanılması durumunda en iyi sonucun 256 nöron kullanılan derin öğrenme yapısı olduğu anlaşılmaktadır. 256 nöronlu yapıda MAPE değeri %3,13, MAE değeri 0,015, RMSE değeri 0,019 olarak ortaya çıkmıştır. Yüksek doğrulukta tahmin yapıldığı anlaşılmaktadır. Şekil 8'de tek katmanlı ve 256 nöronlu eğitim test seti sonucuna ait grafik verilmiş olup R^2 değerlerine bakıldığında ortalama başarı oranı %98,8'dir.

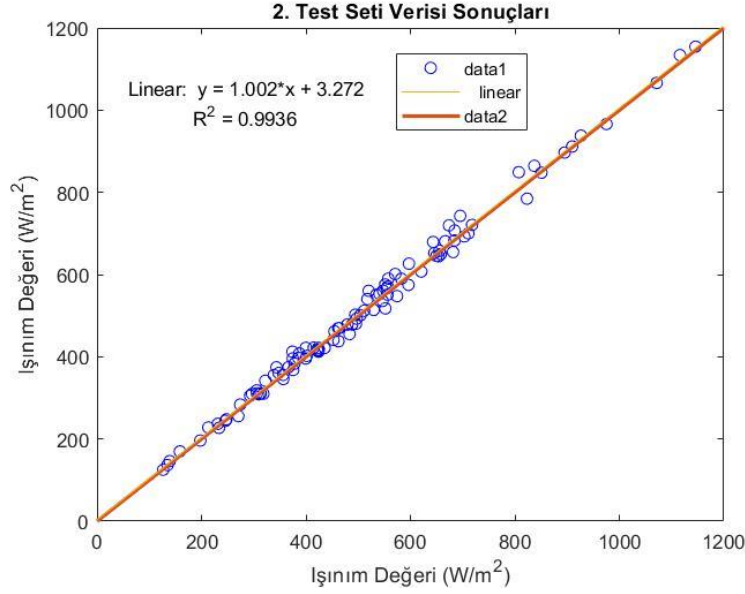


Şekil 8. Tek Katmanlı ve 256 Nöronlu Eğitim Test Seti Grafiği

Tablo 6. Tek Katmanlı 2. Test Seti Verilerine Ait Değerler

	16 NÖRON	32 NÖRON	64 NÖRON	128 NÖRON	256 NÖRON	512 NÖRON
RMSE (kW)	0,041	0,030	0,020	0,019	0,017	0,021
MAE (kW)	0,031	0,024	0,016	0,015	0,013	0,017
MAPE	6,261	4,942	3,509	3,150	2,839	3,380
R ²	0,967	0,983	0,992	0,993	0,994	0,993
Zaman	1 Dakika 51 Saniye	1 Dakika 52 Saniye	1 Dakika 53 Saniye	1 Dakika 53 Saniye	2 Dakika 1 Saniye	2 Dakika 4 Saniye

Tek katman kullanılarak yapılan 2. test sonucunda Tablo 6'da gösterilen değerler elde edilmiştir. Tek katmanlı 2. test seti verilerine ait tablo incelendiğinde tek katman kullanılarak 16 nöronlu yapıda ortalama MAPE değerinin %6,26, 32 nöronlu yapıda ortalama MAPE değerinin %4,94, 64 nöronlu yapıda ortalama MAPE değerinin %3,50, 128 nöronlu yapıda ortalama MAPE değerinin %3,15, 256 nöronlu yapıda ortalama MAPE değerinin %2,83, 512 nöronlu yapıda ortalama MAPE değerinin %3,38, olduğu görülmektedir. Bu değerler %10'dan küçük olduğundan eğitim başarısının çok yüksek olduğu görülmektedir. 2. test verileri içerisinde tek katman kullanılması durumunda en iyi sonucun 256 nöron kullanılan derin öğrenme yapısı olduğu anlaşılmaktadır. 256 nöronlu yapıda MAPE değeri %2,83, MAE değeri 0,013, RMSE değeri 0,017 olarak ortaya çıkmıştır. Yüksek doğrulukta tahmin yapıldığı anlaşılmaktadır. Şekil 9'da tek katmanlı ve 256 nöronlu 2. test seti sonucuna ait grafik verilmiş olup R² değerlerine bakıldığında ortalama başarı oranı %99,3'dir.

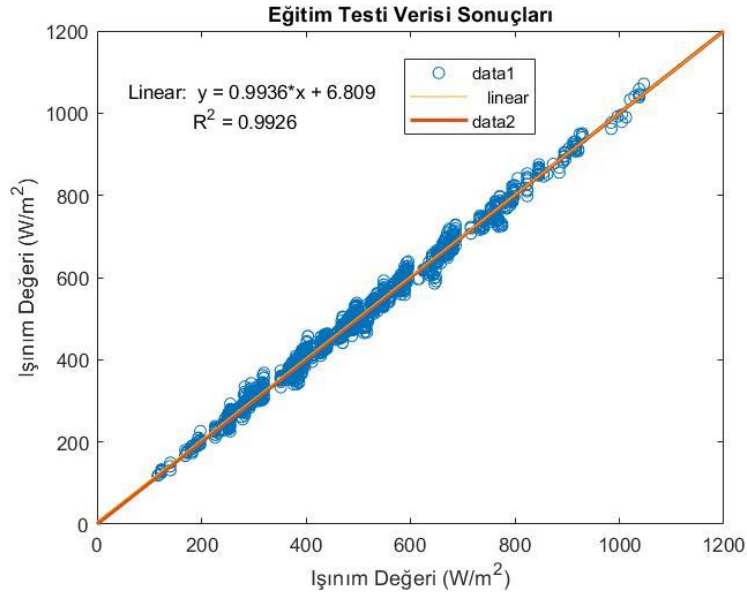


Şekil 9. Tek Katmanlı ve 256 Nöronlu 2. Test Seti Grafiği

Tablo 7. İki Katmanlı Eğitim Test Seti Verilerine Ait Değerler

	16 NÖRON	32 NÖRON	64 NÖRON	128 NÖRON	256 NÖRON	512 NÖRON
RMSE (kW)	0,025	0,021	0,015	0,016	0,016	0,019
MAE (kW)	0,020	0,016	0,012	0,012	0,012	0,015
MAPE	4,178	3,485	2,608	2,602	2,634	3,217
R ²	0,981	0,988	0,993	0,994	0,994	0,994
Zaman	2 Dakika 4 Saniye	2 Dakika 5 Saniye	2 Dakika 17 Saniye	2 Dakika 27 Saniye	2 Dakika 57 Saniye	4 Dakika 19 Saniye

İki katman kullanılarak yapılan eğitim sonucunda Tablo 7'de gösterilen değerler elde edilmiştir. İki katmanlı eğitim test seti verilerine ait tablo incelendiğinde iki katman kullanılarak 16 nöronlu yapıda ortalama MAPE değerinin %4,17, 32 nöronlu yapıda ortalama MAPE değerinin %3,48, 64 nöronlu yapıda ortalama MAPE değerinin %2,60, 128 nöronlu yapıda ortalama MAPE değerinin %2,60, 256 nöronlu yapıda ortalama MAPE değerinin %2,63, 512 nöronlu yapıda ortalama MAPE değerinin %3,21 olduğu görülmektedir. İki katmanlı 128 nöron bulunan yapıda ortalama MAPE değerinin 64 nöron bulunan yapıya göre daha düşük olmasına rağmen geçen zaman açısından incelendiğinde 64 nöron kullanılan yapının daha verimli olacağı düşünülmektedir. Bu değerler %10'dan küçük olduğundan eğitim başarısının çok yüksek olduğu görülmektedir. Eğitim test verileri içerisinde iki katman kullanılması durumunda en iyi sonucun 64 nöron kullanılan derin öğrenme yapısı olduğu anlaşılmaktadır. 64 nöronlu yapıda MAPE değeri %2,60, MAE değeri 0,012, RMSE değeri 0,015 olarak ortaya çıkmıştır. Yüksek doğrulukta tahmin yapıldığı anlaşılmaktadır. Şekil 10'da iki katmanlı ve 64 nöronlu eğitim test seti sonucuna ait grafik verilmiş olup R² değerlerine bakıldığında ortalama başarı oranı %99,2'dir.




Şekil 10. İki Katmanlı ve 64 Nöronlu Eğitim Test Seti Grafiği

Tablo 8. İki Katmanlı 2. Test Seti Verilerine Ait Değerler

	16 NÖRON	32 NÖRON	64 NÖRON	128 NÖRON	256 NÖRON	512 NÖRON
RMSE (kW)	0,022	0,018	0,014	0,016	0,013	0,020
MAE (kW)	0,017	0,014	0,011	0,012	0,011	0,016
MAPE	3,626	2,893	2,367	2,441	2,250	3,308
R ²	0,990	0,994	0,996	0,996	0,997	0,996
Zaman	2 Dakika 4 Saniye	2 Dakika 5 Saniye	2 Dakika 17 Saniye	2 Dakika 27 Saniye	2 Dakika 57 Saniye	4 Dakika 19 Saniye

İki katman kullanılarak yapılan 2. test sonucunda Tablo 8'de gösterilen değerler elde edilmiştir. İki katmanlı 2. test seti verilerine ait tablo incelendiğinde iki katman kullanılarak 16 nöronlu yapıda ortalama MAPE değerinin %3,62, 32 nöronlu yapıda ortalama MAPE değerinin %2,89, 64 nöronlu yapıda ortalama MAPE değerinin %2,36, 128 nöronlu yapıda ortalama MAPE değerinin %2,44, 256 nöronlu yapıda ortalama MAPE değerinin %2,25, 512 nöronlu yapıda ortalama MAPE değerinin %3,30 olduğu görülmektedir. Bu değerler %10'dan küçük olduğundan eğitim başarısının çok yüksek olduğu görülmektedir. 2. test seti verileri içerisinde iki katman kullanılması durumunda en iyi sonucun 256 nöron kullanılan derin öğrenme yapısı olduğu anlaşılmaktadır. 256 nöronlu yapıda MAPE değeri %2,25, MAE değeri 0,011, RMSE değeri 0,013 olarak ortaya çıkmıştır. Yüksek doğrulukta tahmin yapıldığı anlaşılmaktadır. Şekil 11'de iki katmanlı ve 256 nöronlu 2. test seti sonucuna ait grafik verilmiş olup R² değerlerine bakıldığında ortalama başarı oranı %99,7'dir.



Şekil 11. İki Katmanlı ve 256 Nöronlu 2. Test Seti Grafiği


Tablo 9. Üç Katmanlı Eğitim Test Seti Verilerine Ait Değerler

	16 NÖRON	32 NÖRON	64 NÖRON	128 NÖRON	256 NÖRON	512 NÖRON
RMSE (kW)	0,024	0,017	0,012	0,013	0,011	0,011
MAE (kW)	0,018	0,013	0,009	0,010	0,009	0,009
MAPE	3,879	2,831	2,016	2,261	1,931	1,866
R ²	0,982	0,991	0,995	0,996	0,996	0,996
Zaman	2 Dakika 15 Saniye	2 Dakika 17 Saniye	2 Dakika 32 Saniye	2 Dakika 47 Saniye	3 Dakika 36 Saniye	5 Dakika 55 Saniye

Üç katman kullanılarak yapılan eğitim sonucunda Tablo 9'da gösterilen değerler elde edilmiştir. Üç katmanlı eğitim test seti verilerine ait tablo incelendiğinde üç katman kullanılarak 16 nöronlu yapıda ortalama MAPE değerinin %3,87, 32 nöronlu yapıda ortalama MAPE değerinin %2,83, 64 nöronlu yapıda ortalama MAPE değerinin %2,01, 128 nöronlu yapıda ortalama MAPE değerinin %2,26, 256 nöronlu yapıda ortalama MAPE değerinin %1,93, 512 nöronlu yapıda ortalama MAPE değerinin %1,86 olduğu görülmektedir. Üç katmanlı 256 nöron bulunan yapıda ve 512 nöron bulunan yapıda ortalama MAPE değerinin 64 nöron bulunan yapıya göre daha düşük olmasına rağmen geçen zaman açısından incelendiğinde 64 nöron kullanılan yapının daha verimli olacağı düşünülmektedir. Bu değerler %10'dan küçük olduğundan eğitim başarısının çok yüksek olduğu görülmektedir. Eğitim test verileri içerisinde üç katman kullanılması durumunda en iyi sonucun 64 nöron kullanılan derin öğrenme yapısı olduğu anlaşılmaktadır. 64 nöronlu yapıda MAPE değeri %2,01, MAE değeri 0,009, RMSE değeri 0,012 olarak ortaya çıkmıştır. Yüksek doğrulukta tahmin yapıldığı anlaşılmaktadır. Şekil 12'de üç katmanlı ve 64 nöronlu eğitim test seti sonucuna ait grafik verilmiş olup R² değerlerine bakıldığında ortalama başarı oranı %99,5'dir.

Üç katman kullanılarak yapılan 2. test sonucunda Tablo 10'da gösterilen değerler elde edilmiştir. Üç katmanlı 2. test seti verilerine ait tablo incelendiğinde üç katman kullanılarak 16 nöronlu yapıda ortalama MAPE değerinin %3,66, 32 nöronlu yapıda ortalama MAPE değerinin %2,49, 64 nöronlu yapıda ortalama MAPE değerinin %1,71, 128 nöronlu yapıda ortalama MAPE değerinin %2,19, 256 nöronlu yapıda ortalama MAPE değerinin %1,95, 512 nöronlu yapıda ortalama MAPE değerinin %1,48 olduğu görülmektedir. Üç katmanlı 512 nöron bulunan yapıda ortalama MAPE değerinin 64 nöron bulunan yapıya göre daha düşük olmasına rağmen geçen zaman açısından incelendiğinde 64 nöron kullanılan yapının daha verimli olacağı düşünülmektedir. Bu değerler %10'dan küçük olduğundan eğitim başarısının çok yüksek olduğu görülmektedir. 2. test verileri içerisinde üç katman kullanılması durumunda en iyi sonucun 64 nöron kullanılan derin öğrenme yapısı olduğu anlaşılmaktadır. 64 nöronlu yapıda MAPE değeri %1,71,


MAE değeri 0,008, RMSE değeri 0,010 olarak ortaya çıkmıştır. Yüksek doğrulukta tahmin yapıldığı anlaşılmaktadır. Şekil 13'te üç katmanlı ve 64 nöronlu 2. test seti sonucuna ait grafik verilmiş olup R^2 değerlerine bakıldığında ortalama başarı oranı %99,8'dir.



Şekil 12. Üç Katmanlı ve 64 Nöronlu Eğitim Test Seti Grafiği

Tablo 10. Üç Katmanlı 2. Test Seti Verilerine Ait Değerler

	16 NÖRON	32 NÖRON	64 NÖRON	128 NÖRON	256 NÖRON	512 NÖRON
RMSE (kW)	0,022	0,015	0,010	0,013	0,012	0,009
MAE (kW)	0,017	0,012	0,008	0,010	0,009	0,007
MAPE	3,668	2,492	1,712	2,197	1,953	1,482
R^2	0,990	0,995	0,998	0,998	0,998	0,998
Zaman	2 Dakika 15 Saniye	2 Dakika 17 Saniye	2 Dakika 32 Saniye	2 Dakika 47 Saniye	3 Dakika 36 Saniye	5 Dakika 55 Saniye



Şekil 13. Üç Katmanlı ve 64 Nöronlu 2. Test Seti Grafiği

SONUÇ

Yapılan çalışmada kısmi gölgelenme koşulları altında bulunan FV sitemlerin çıkış gücünün tahmin edilmesi için derin öğrenme kullanılarak eğitilmesi durumunda verimlerinin nasıl artırılacağı araştırılmıştır. Yapılan çalışmada 4 tane seri bağlı FV panelin giriş ışınım değerleri 100'er aralıklarla artırılarak toplam 10000 veri elde edilmiştir. Bu veriler MATLAB/Simulink ile modellenmiş ve çıkış güçleri elde edilmiştir. 7000 veri eğitim, 1500 veri doğrulama, 1500 veride test için ayrılmış ve bu verilerin çalışma boyunca aynı gurubun içinde kalması sağlanarak olası hataların önüne geçilmesi amaçlanmıştır. Ayrıca eğitime hiç girmemiş 100 veri ile sistem teste tabi tutulmuştur. Derin öğrenme kullanılarak katman sayılarının ve nöron sayılarının eğitim üzerine etkileri incelenmiştir. Her nöron sayısı için eğitim üç defa tekrarlanmış ve ortalama sonuçları alınarak MAPE, MAE, RMSE ve R² istatistiksel değerlendirme kriterleri ile değerlendirilmiştir.

Çalışma sonucunda derin öğrenme ile tek katman kullanılması durumunda 256 nöron bulunan yapının hem eğitim test setinde hem de 2. test setinde en iyi sonucu verdiği anlaşılmaktadır. İki katman kullanılması durumunda eğitim test setinde 64 nöron bulunan yapının, 2. test setinde ise 256 nöron bulunan yapının en iyi sonucu verdiği anlaşılmaktadır. Üç katman kullanılması durumunda 64 nöron bulunan yapının hem eğitim test setinde hem de 2. test setinde en iyi sonucu verdiği anlaşılmaktadır. Tüm katmanlar içerisinde en iyi sonucu eğitim test setinde MAPE değeri %2,01 ile, 2. test setinde ise MAPE değeri %1,71 ile üç katman ve 64 nöron bulunan sistemden elde edilebileceği gösterilmiştir.

Derin öğrenme yöntemi, FV paneller başta olmak üzere yenilenebilir enerji kaynaklarının daha verimli kullanılması konusunda ileride yapılacak çalışmalarda kullanılabilir. Çalışmada elde edilen veriler kullanılarak KGK altında çalışan panellerin pratik uygulamalarda panel verimlilikleri artırılabilir. GPU teknolojisindeki gelişmeler KGK altında bulunan FV panellerin GMGN'nın tespit edilmesinde derin öğrenme yönteminin başarı oranını artıracaktır.

KAYNAKLAR

- Alaskar, H., & Saba, T. (2021). Machine Learning and Deep Learning: A Comparative Review. *Proceedings of Integrated Intelligence Enable Networks and Computing*, 143-150.
- Balkan, A. (2022). *Şebeke bağlantılı bir fotovoltaik güç üretim santralinin tasarım aşamaları ve güç boyutlandırma faktörünün önemi*. Yüksek Lisans Tezi, Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü, Çankırı.
- Bassam, A.-H. (2018). *Maximum Power Point Tracking Controlled Boost Converter Desing For Battery Charger*. (MSc. Thesis). Yıldız Technical University,
- Can, Y. (2020). *Makine Öğrenmesi ve Derin Öğrenme Yöntemleri İle Dizel Motor Turbo Kompresör Sisteminin Modellenmesi*.
- Dandıl, E., & Gürgen, E. (2019). Yapay Sinir Ağları Kullanılarak Fotovoltaik Panel Güç Çıktılarının Tahmini ve Sezgisel Algoritmalar ile Karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*(16), 146-158.
- EİGM. (2021). Yenilenebilir Enerji Kaynakları. <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-gunes> Accessed 15.05.2021
- Eltez, E. B. (2022). *Otopark üstü fotovoltaik güç sisteminin parametrik tasarımı*. Yüksek Lisans Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*(16), 8-15.
- Karakaya, H. B. (2021). *Fotovoltaik sistemlerde maksimum güç noktasının takibi için kullanılan optimizasyon algoritmalarının performansının değerlendirilmesi*. Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş.
- Keçecioglu, Ö. F., Tekin, M., Ahmet, G., Açıkgöz, H., Gemci, A., & Şekkeli, M. (2015). Bir güneş enerji santralinin elektrik şebekesindeki güç kalitesi parametrelerine etkisinin incelenmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 18(2), 17-24.
- Keskin, Y. E. (2014). *Fotovoltaik sistemlerde maksimum güç noktası izleme yöntemlerinin karşılaştırılması*. Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü,

- Kılıç, E. (2019). DA-DA yükselten dönüştürücü ile elektrikli araç batarya şarj cihazı tasarımı. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 22(4), 281-287.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lewis Colin, D. (1982). Industrial and business forecasting methods. *Butterworth & Co Publishers Ltd*.
- Mathew, A., Amudha, P., & Sivakumari, S. (2020). *Deep learning techniques: an overview*. Paper presented at the International conference on advanced machine learning technologies and applications.
- Mellit, A., Massi Pavan, A., Oglari, E., Leva, S., & Lughi, V. (2020). Advanced methods for photovoltaic output power forecasting: A review. *Applied Sciences*, 10(2), 487.
- Mellit, A., Pavan, A. M., & Lughi, V. (2014). Short-term forecasting of power production in a large-scale photovoltaic plant. *Solar Energy*, 105, 401-413.
- Özçalık, H. R., Yılmaz, S., & Kılıç, E. (2013). Güneş Pilinin Bir Diyotlu Eşdeğer Devre Yardımıyla Matematiksel Modelinin Çıkartılması ve Parametrelerinin İncelenmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 16(1), 23-29.
- Özçelik, M. A. (2015). Fotovoltaik sistemlerde verim ve performansın artırılmasına yönelik maksimum güç noktası izleyicisi tasarımı.
- Qassab, K. S. Q. (2015). *Design and Simulation Of Maximum Power Point Tracking Controller for Solar Photovoltaic Systems by Perturb and Observe Method*. Yüksek Lisans Tezi, Atılım Üniversitesi Fen Bilimleri Enstitüsü, Ankara,
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Shinde, P. P., & Shah, S. (2018). *A review of machine learning and deep learning applications*. Paper presented at the 2018 Fourth international conference on computing communication control and automation (ICCUBEA).
- Witt, S. F., & Witt, C. A. (1992). *Modeling and forecasting demand in tourism*: Academic Press Ltd.
- Yousefi-Azar, M., & Hamey, L. (2017). Text summarization using unsupervised deep learning. *Expert Systems with Applications*, 68, 93-105.