

Farklı Teknolojilerle Üretilmiş Fotovoltaik Panellerin Çıkış Güçlerinin Modellenmesi

Output Power Modeling of PV Modules Produced by Different Technologies

Emre AKARSLAN, Murat ORHUN, Fatih Onur HOCAOĞLU, Said Mahmut ÇINAR

Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü
Afyon Kocatepe Üniversitesi

e.akarslan@gmail.com, muratorhun@windowslive.com, fohocaoglu@gmail.com, smcinar@gmail.com

Özet

Bu çalışmada Afyon Kocatepe Üniversitesi ANS Kampusunda tesis edilmiş sabit eğimli platform üzerine yerleştirilmiş mono-kristal, poli-kristal ve ince film teknolojisiyle üretilmiş güneş panellerinin çıkış güçlerinin Yapay Sinir Ağlarıyla modellenmesi amaçlanmıştır. Bu amaçla, her bir panelin çıkış akımı, gerilimi, yüzey sıcaklığı ile ortam sıcaklığı ve global ışıınım şiddeti verileri ölçülüp kaydedilmiştir. Bu parametrelerin çeşitli varyasyonlarından oluşan girdilere sahip yapay sinir ağı modelleri oluşturulmuştur. Oluşturulan yapay sinir ağları önce eğitilmiş daha sonra test edilmiştir. Bu sayede panellerin performansları karşılaştırılmış, enerji tahmin modelleri oluşturulmuş ve ortam sıcaklığı ile panellerin yüzey sıcaklıklarının panel çıkış gücüne etkisi araştırılmıştır. Elde edilen sonuçlar yorumlanarak tartışılmıştır.

Abstract

In this study output powers of three PV modules with different production structures (monocrystalline, polycrystalline and thin film) are studied. The modules are located on a fixed platform built at ANS campus of Afyon Kocatepe University. Output Powers of the modules are modelled using Neural Networks. To model the output Powers first output currents, voltages, surface temperatures of the panels are measured. Besides ambient temperature and global solar radiations are measured and collected. Second, using various combinations of these parameters different Neural Network structures are built. All NN structures are first trained then tested. By this way not only the performances of the panels are tested and energy forecasting models are built but also the effect of temperature (both ambient and surface) parameter on module performance is explored. Finally the result are interpreted and discussed, in detail.

1. Giriş

Güneş enerjisinden elektrik enerjisi üreten sistemlerin (PV) maliyetleri giderek azalmakta ve bunun sonucu olarak bu tür sistemlerin kullanımları giderek yaygınlaşmaktadır. Ancak çeşitli atmosferik olaylar nedeniyle PV sistemlerden herhangi bir zamanda ne kadar elektrik üretilebileceği kesin olarak hesaplanamamaktadır. Literatürde çeşitli güneş panellerinin

enerji üretimlerini tahmin etmek için çeşitli çalışmalar gerçekleştirilmiştir. Bu çalışmalar aşağıda özetlenmiştir.

Sfetsos and Coonick (2000) çalışmalarında bir adım sonraki ışıınım şiddetini tahmin etmek için yapay sinir ağlarını kullanmışlardır [1]. Diğer taraftan Chowdhury and Rahman (1987) açık hava modelini normalize ederek yarımsar saatlik tahminleme yapmışlardır [2]. Bir başka çalışmada Hammer ve arkadaşları uydudan alınmış verileri kullanarak güneş ışıınım şiddeti verilerinin tahmini için istatistiksel bir yöntem geliştirmişlerdir [3]. Su ve arkadaşları gride bağlı güneş modüllerinin çıkış güçlerini ve verimlerini gerçek zamanlı olarak modellemişlerdir [4]. Hocaoglu ve arkadaşları çalışmalarında optimal katsayılı lineer filtreler ve yapay sinir ağları kullanılarak saatlik ışıınım şiddeti tahmini yapmışlardır [5]. Bir başka çalışmada ise Chupong and Plangklang (2011) Thailand'da bulunan gride bağlı bir sistemin çıkış gücünü ışıınım şiddeti verileri kullanılmaksızın tahmin eden bir yöntem geliştirmişlerdir [6].

Bu çalışmada Afyon Kocatepe Üniversitesi'ne farklı teknolojilerle üretilmiş, aynı çıkış gücüne sahip PV paneller sabit açılı bir platform üzerine konumlandırılmış ve panellerden üretilen elektrik enerjisinin üretildiği anda tüketilmesi sağlanmıştır. Böylece panellerin anlık elektrik üretimleri ölçülmüş ve kaydedilmiştir. Panellerin yüzey sıcaklıkları ve ortam sıcaklığı da uygun sensörler yardımıyla ölçülüp kaydedilmiştir. Bölge içerisinde yüzeye paralel bir zemin üzerine yerleştirilen bir pirinometre yardımıyla bölgeden küresel ışıınım şiddeti verileri ölçülmüş ve kaydedilmiştir. Tesis edilen sistem ve ölçülen parametrelere ilişkin bilgiler 2. Bölümde sunulmuştur. Ölçülüp kaydedilen parametreler kullanılarak enerji tahmin modelleri oluşturulması ve elektrik enerjisi üretimine sıcaklığın etkisinin araştırılması hedeflenmiştir. Oluşturulan modeller 3. Bölümde anlatılmaktadır. Son olarak elde edilen sonuçlar 4. Bölümde sunulmuş ve tartışılmıştır.

2. Tesis Edilen Sisteme Ait Bilgiler

Çalışmada Afyon Kocatepe Üniversitesi ANS Kampusu Güneş ve Rüzgar Enerjisi Uygulama ve Araştırma Merkezi civarına sabit bir platform tesis edilmiştir. Tesis edilen sistem üzerine çizelge 1 de karakteristik özellikleri yer alan

monokristal, polikristal ve ince film teknolojisiyle üretilmiş paneller yerleştirilmiştir. Her bir panel üzerine sıcaklık sensörleri yerleştirilmiştir. Üzerine panellerin yerleştirildiği platform Şekil 1 de görülmektedir.


Çizelge 1: Alınan güneş panellerinin teknik özellikleri

Panel Tipi	Monokristal	İncefilm	Polikristal
Standart Güç (W)	60	60	60
Kısa Devre Akımı (A)	3,73	1,57	3,97
Açık Devre Gerilimi (V)	21,6	61,44	21,7
Mak. Güç Akımı (A)	3,47	1,21	3,41
Mak. Güç Gerilimi (V)	17,3	45,45	17,6
Mak. Sistem Gerilimi (V)	760	1000	1000



Şekil 1: Sabit Platform üzerinde güneş panellerinin görünümü

Panellerin çıkış güçlerini hesaplayabilmek amacıyla üretilen enerjinin üretildiği anda tüketilmesi hedeflenmiş ve otomobil sektöründe kullanılan 24 V, 75 W far ampulleri kullanarak Şekil 2'de sunulan yük bankası geliştirilmiştir.



Şekil 2: Yük bankası

Yük bankası üzerinden akım ve gerilim değerleri ölçülmüş ve bu değerler yardımıyla panellerin çıkış güçleri hesaplanmıştır. Panellerden uzak bir yere bir sıcaklık sensörü daha yerleştirilmiş ve bu sayede dış ortam sıcaklıklarının ölçülmesi sağlanmıştır. Ölçülen tüm veriler bir programlanabilen lojik


ünite ve bu ünite ile haberleşebilen bir bilgisayar sayesinde onar dakikalık sıklıklarla kaydedilmiştir.

3. Yapay Sinir Ağları ile Tahmin Modellerinin Oluşturulması

3.1. Yapay Sinir Ağları:

Yapay sinir ağları, insan beyninin çalışma prensibi baz alınarak modellenen sistemlerdir. Bu sistemler, kontrolden robotik uygulamalarına, örüntü tanımadan tahmin uygulamalarına, güç sistemlerinden optimizasyona kadar çok geniş bir kullanım alanına sahiptir. Bu sistemler özellikle sistem modelleme uygulamalarında çok faydalıdır [7].

Bir yapay sinir ağı genellikle bir girdi katmanı, belirlenen sayıda gizli katman ve bir çıkış katmanından oluşur. Bir katmanda bulunan nöronlar, diğer katmandaki her bir nöronla birbirine bağlantılıdır. Biyolojide, bu bağlantılara sinaps adı verilmektedir. Her bir sinapsın bir ağırlık değeri vardır ve bu sinaps üzerinden gönderilen bir sinyal, bu ağırlık değeri ile çarpılır. Şekil 3'te 2 gizli katmana sahip bir ağ mimarisi görülmektedir.



Şekil 3: İki gizli katmana sahip bir yapay sinir ağı mimarisi

Aktivasyon fonksiyonları ise bir YSA'da nöronun çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler çoğunlukla [0,1] veya [-1,1] arasındadır. Lineer ve doğrusal olmayan aktivasyon fonksiyonlarının yapay sinir ağlarında kullanılması karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır. Mühendislikte ve pek çok alanda en çok kullanılan öğrenme algoritması, geriye yayılma algoritmasıdır. Bunun en büyük nedeni, öğrenme kapasitesinin yüksek ve algoritmasının basit olmasıdır [8].

Geri yayımlı ağı; sistem öğrenirken hataların, çıktı katmanından girdi katmanına doğru geriye yayıldığı ağıdır. Gizli birimler hedef değeri bilemedikleri için öğrenemezler. Önceki katmandan hataları alıp geriye doğru yayarak öğrendikleri için bu çok gerekli bir süreçtir. Çıktı değeri karşılaştırma yapmak için yalnızca bir hedef değerine sahiptir. Hatalar düğümler yoluyla geri iletilir. Bu sayede bağlantı ağırlıkları sürekli değiştirilir. Ağırlıklarda hatalar kabul edilebilir seviyeye küçülünceye kadar öğrenme sürer [9].

Hatayı belirlemek için farklı hesaplama yöntemleri mevcuttur. Bunlardan en sık kullanılanı ortalama karesel hataların karekökü (RMSE)'dir. Ortalama karesel hataların karekökü;

$$RMSE = \sqrt{(y_g - y_t)^2 / n} \quad (1)$$

formülü ile hesaplanır. Burada y_g gerçek değeri, y_t ise algoritma çıktısını ifade etmektedir. Hatanın sıfır ya da sıfıra çok yakın olması ağın iyi eğitildiği anlamına gelir [10].

3.2. Modelleme

2012 yılının Nisan ve Mayıs aylarında onar dakika sıklıkla ölçülüp kaydedilmiş olan veriler kullanılarak çizelge 2 de verilen farklı Yapay Sinir Ağı Modelleri oluşturulmuştur.

Çizelge 2: Alınan güneş panellerinin teknik özellikleri


	GİRDİ SAYISI	GİRDİLER	ÇIKTILAR
Model-1	3	Panel Yüzey Sıcaklığı, Ortam Sıcaklığı, Güneş Işınım Şiddeti Verileri	Panel Çıkış Gücü
Model-2	2	Panel Yüzey Sıcaklığı, Güneş Işınım Şiddeti Verileri	Panel Çıkış Gücü
Model-3	2	Panel Yüzey Sıcaklığı, Ortam Sıcaklığı	Panel Çıkış Gücü
Model-4	1	Panel Yüzey Sıcaklığı	Panel Çıkış Gücü
Model-5	1	Ortam Sıcaklığı	Panel Çıkış Gücü

İnce Film, Mono kristal ve Poli kristal teknolojilerle üretilmiş fotovoltaik panellerden elde edilen veriler, panel yüzey sıcaklıkları, ortam sıcaklıkları ve güneş ışınım şiddeti verileri kullanılarak çizelge 2 deki yapılar oluşturulmuştur. Verilerin %80'i ağın eğitimi için, geriye kalan %20'si ise ağın testi için kullanılmıştır. Test ve eğitim verileri oluşturulurken Yapay Sinir Ağı modellerinin verilerin genel davranışını ezberlemesini engellemek amacıyla veriler rasgele karıştırılmıştır. Tüm YSA modelleri her bir panel için eğitilmiş ve test edilmiştir. Eğitim her bir model için 100 aşama tekrarlanmıştır. Ancak tüm modeller için eğitimin 20 aşama sonunda büyük ölçüde tamamlandığı gözlemlenmiştir. YSA modelleri farklı algoritmalarla ve farklı sayıda gizli katman sinir hücresi sayısı kullanılarak eğitilmiş ve test edilmiştir. En iyi eğitim Levenberg-Marquard algoritmasından elde edilirken gizli katmandaki nöron sayısının 8 olması durumunda eğitimin daha kısa sürede tamamlandığı tespit edilmiştir. Eğitim ve test işlemleri sonucunda elde edilen ağ çıktıları (panellerden üretilen güç değerleri) gerçek güç üretim değerleriyle ortalama karesel hatanın karekökü (Root Mean Square Error- RMSE) kriterine göre karşılaştırılmıştır. Karşılaştırma sonuçları Çizelge 3'de sunulmuştur.

Çizelge 3: Modellere ait RMSE değerleri


Model No	Train			Test		
	Mono Kristal	İnce Film	Poli Kristal	Mono Kristal	İnce Film	Poli Kristal
1	5,4514	2,239	6,1453	6,4553	2,3858	7,0268
2	5,2908	2,001	5,9264	5,9912	2,2784	6,6742
3	6,6716	2,541	6,3416	6,8161	2,7007	6,8045
4	6,9264	2,688	7,2117	7,2290	2,9190	7,6679
5	5,5777	3,426	9,3992	9,7273	3,6672	9,6811

Ölçülen veriler ile Ağ çıktıların değişimleri her üç panel tipi için de incelenmiş olup ince film teknolojisi ile üretilmiş olan verilere ait sonuçlar Şekil 4'te sunulmuştur.




Şekil 4: İnce Film Teknolojisi ile üretilmiş panellere ait ölçülmüş verilerin ve test çıktıların aynı grafik üzerinde görünümü.

Şekil 4'te veri sayısının fazla olması tahmin performansının grafik üzerinden anlaşılmasını zorlaştırmaktadır. Bu nedenle Şekil 4'ün bir bölümünün büyütülmüş hali Şekil 5'te sunulmuştur.



Şekil 5: Şekil 4'ün rasgele seçilmiş bir bölümünün büyütülmüş hali

Ağ tarafından bulunan verilerin ölçülmüş verilere göre korelasyonunun incelenmesi amacıyla verilerin birbirlerine göre değişimleri Şekil 6'da çizdirilmiştir.



Şekil 6: Ölçülmüş olan verilerin Ağ çıktıları ile değişimi

4. Sonuçlar

Bu çalışmada farklı teknolojilerle üretilmiş aynı çıkış gücüne sahip üç panelin enerji üretimlerine etki eden parametreler incelenmiştir. Bu amaçla farklı girdilere sahip Yapay Sinir Ağı yapıları oluşturulmuş ve aynı parametrelerle eğitilmiştir. Eğitilen yapılar daha sonra ağa sunulmamış verilerle test edilmiştir. Sonuçlar incelendiğinde panel yüzey sıcaklığının panel çıkış güçlerine önemli ölçüde etkisinin bulunduğu anlaşılmaktadır. Diğer taraftan panel yüzey sıcaklığı yerine ortam sıcaklığı girdi olarak kullanıldığında veya ortam sıcaklığı panel yüzey sıcaklığı ile birlikte girdi olarak kullanıldığında enerji tahmin performansının olumsuz yönde etkilendiği gözlemlenmiştir. Bu duruma güneşin olmadığı zaman dilimlerinde panellerde üretim olmadığı için yüzey sıcaklıklarının ortam sıcaklıklarına yaklaşmasının sebep olduğu düşünülmektedir. Güneşin olmadığı zaman dilimlerinin girdi olarak düşünülmediği modellerin oluşturulması, dünya dışındaki ışınım şiddeti verilerinin ve diğer meteorolojik parametrelerinin de kullanıldığı elektrik üretim modelleri geliştirilmesi ileride yapılacak çalışmalar olarak düşünülebilir.

5. Teşekkür

Bu çalışma 111E134 numaralı TUBITAK projesi kapsamında gerçekleştirilmiştir.

6. Kaynaklar

- [1] Sfetos, A. and Coonick, A., "Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques", *Solar Energy*, 68 (2), 169-178, 2000.
- [2] Chowdhury, B., Rahman, S., "Forecasting sub-hourly solar irradiance for prediction of photovoltaic output", In: *IEEE Photovoltaic Specialists Conference*, 19th, New Orleans, LA, 1987, 171-176.
- [3] A. Hammer, D. Heinemann, E. Lorenz, B. Lücke, "Short-term forecasting of solar radiation: a statistical approach using satellite data" *Solar Energy*, Volume 139-150, 1999.
- [4] Su, Y., Chan L., Shu, L., Tsui, K.L., "Real-time prediction models for output power and efficiency of grid-connected solar photovoltaic systems", *Applied Energy*, Volume 93, 319-326, 2012.
- [5] Hocaoglu, F.O., Gerek, O.N., Kurban M., "Hourly solar radiation forecasting using optimal coefficient 2-D linear filters and feed-forward neural networks", *Solar Energy*, Volume 82, Issue 8, 714-726, 2008.
- [6] Chupong, C., Plangklang, B., "Forecasting power output of PV grid connected system in Thailand without using solar radiation measurement", *Energy Procedia*, Volume 9, Pages 230-237, 2011.
- [7] Kalogirou, S. A. "Artificial neural networks in renewable energy systems applications: a review", *Renewable and Sustainable Energy Reviews*. Volume 5, Issue 4, Pages 373-401, 2001.
- [8] Kaya, İ., Oktay, S., Engin, O. "Kalite kontrol problemlerinin çözümünde yapay sinir ağlarının kullanımı", *Erciyes Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, 21 (1-2), 92-107, 2005.
- [9] Lawrence R., "Forecasting stock prices using neural networks", *Department of Computer Science, University of Manitoba*, pp. 5-10, 1997.
- [10] Caner, M., Akarslan, E., "Mermer Kesme İşleminde Spesifik Enerji Faktörünün ANFIS ve YSA Yöntemleri ile Tahmini", *Pamukkale Üniversitesi, Mühendislik Bilimleri Dergisi*, Cilt 15, Sayı 2, 221-226, 2009.