

Yapay Sinir Ağı ve ANFIS Kullanılarak Meteorolojik Verilere Bağlı Güneş Enerjisi Tahmini

Serdar SOMUNCU¹, Canan ORAL^{2*}

¹Amasya Üniversitesi, Fen Bilimleri Enstitüsü, Yenilenebilir Enerji ve Uygulamaları Anabilim Dalı, 05100, Amasya

²Amasya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 05100, Amasya

¹<https://orcid.org/0000-0002-8632-289X>

²<https://orcid.org/0000-0001-9819-3979>

*Sorumlu yazar: canan.oral@amasya.edu.tr

Araştırma Makalesi

Makale Tarihiçesi:

Geliş tarihi: 07.09.2023

Kabul tarihi: 09.12.2023

Online Yayınlanma: 16.09.2024

Anahtar Kelimeler:

Yenilenebilir enerji

Yapay sinir ağı

Uyarlamalı bulanık yapay sinir ağı

çıkarma sistemi

Tahmin

ÖZ

Son yıllarda, enerjiye olan talep gün geçtikçe artarken, fosil yakıtların giderek azalması ve çevre kirliliğine olan duyarlılığın başlamasıyla, yenilenebilir enerji kaynaklarına olan gereksinim her geçen gün artmaktadır. Özellikle güneş enerjisi kullanımı son zamanlarda hızlı bir ivme göstermiştir. Bu çalışmada, güneş enerji santrali üretim verilerinin meteorolojik verilere bağlı olarak yapay zekâ yöntemlerinden çok katmanlı yapay sinir ağları (ÇKYSA) ve uyarlamalı bulanık yapay sinir ağı çıkarım sistemi (ANFIS) yardımıyla tahmini yapılmıştır. Oluşturulan ÇKYSA ve ANFIS modelleriyle yapılan tahmin değerlerinin ölçülen değerler ile makul düzeyde yakınsadığı saçılma grafiklerinden görülmüştür. ANFIS uygulamasında melez algoritma ve gbellmf üyelik fonksiyonu ve girdi değerleri için 4-4-4 üyelik fonksiyonu kullanılmıştır. ÇKYSA uygulaması sonucunda R^2 değeri 0.9569, MSE değeri 0.1434 ve RMSE değeri 0.3786 olarak elde edilmiştir. ANFIS uygulaması sonucunda R^2 değeri 0.9294, MSE değeri 0.0089 ve RMSE değeri 0.0946 olarak hesaplanmıştır. Test sonuçları sonrası yapılan regresyon eğrilerinde tahminlerin güvenilir ve isabetli olduğu anlaşılmıştır. Enerji sektörü konumunda bulunan santrallerin üretim verileri aynı yöntemlerle hesaplanabilir.

Solar Energy Prediction Based on Meteorological Data Using Artificial Neural Network and ANFIS

Research Article

Article History:

Received: 07.09.2023

Accepted: 09.12.2023

Published online: 16.09.2024

Keywords:

Renewable energy

Artificial neural network

Adaptive fuzzy neural network

inference system

Prediction

ABSTRACT

In recent years, while the demand for energy is increasing every passing day, the need for renewable energy sources is increasing day by day, with the decrease in fossil fuels and the onset of sensitivity to environmental pollution. Particularly, the usage of solar energy has recently increased significantly. In this study, the estimation of solar power plant production data was made with the help of artificial intelligence methods, multilayer artificial neural networks (MLANN), and adaptive fuzzy artificial neural network inference system (ANFIS), depending on meteorological data. It has been seen from the scatter plots that the predicted values made with the created MLANN and ANFIS models converge reasonably with the measured values. In the ANFIS method, hybrid algorithm, gbellmf membership function, and 4-4-4 membership function are used for input values. The R^2 , MSE, and RMSE are obtained as 0.9569, 0.1434, and 0.3786 respectively for the MLANN model. The R^2 , MSE, and RMSE are obtained 0.9294, 0.0089, and 0.0946 respectively for the ANFIS model. It was understood that the estimations were reliable and accurate in the regression curves made after the test results. The production

data of the power plants in the energy sector can be calculated with the same methods.

To Cite: Somuncu S., Oral C. Yapay Sinir Ağı ve ANFIS Kullanılarak Meteorolojik Verilere Bağlı Güneş Enerjisi Tahmini. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi 2024; 7(4): 1685-1701.

1. Giriş

Günümüzde ülkeler enerji gereksiniminin büyük bir bölümünü fosil yakıtlardan karşılamaktadır. Diğer yandan, fosil enerji kaynakları rezervlerinin gün geçtikçe tükenmesi, fosil yakıtların yoğun bir şekilde kullanımından dolayı oluşan iklim değişikliği ve küresel ısınmanın önlenmesi açısından sürdürülebilirliği sağlama ihtiyacı doğmuştur. Bu nedenle, yenilenebilir enerji kaynaklarına olan ihtiyaç ve bilgi-iletişim alanındaki gelişmelerden dolayı enerjiye olan bağımlılık gün geçtikçe artmaktadır.

Yenilenebilir enerjinin tükenmez olması, çevre dostu olması, maliyetlerinin düşmesi ile bu kaynaklara olan talep ve yatırımlar son yıllarda hızla artmaktadır. Güneş enerjisi tahmini, güneş enerjisi santrallerinin enerji piyasasındaki rekabet gücünün artırılmasında, ekonomik ve sosyal kalkınmada fosil yakıtlara olan bağımlılığın azaltılmasında kilit bir unsur temsil etmektedir. Enerji üretiminde yenilenebilir enerji oranını artırmak, ekolojik ve dayanıklı bir elektrik sistemi oluşturmak için gerçekten çok önemlidir. Bu bağlamda güneş enerjisi, enerji üretimi için en umut verici yenilenebilir kaynaklardan biri haline gelmiştir. Bununla birlikte enerjinin durumu; fiyat değişimi, talep değişimi ve yenilenebilir enerji üretiminin istikrarsızlığıyla şekillenmektedir. Güneş enerjisi söz konusu olduğunda bu istikrarsızlık, fotovoltaik (FV) hücrelerin üretiminde kullanılan malzemelere ve aynı zamanda durağan olmayan meteorolojik değişkenler gibi diğer faktörlere de bağlıdır. Bu nedenle, güneş enerjisi alanında, öncelikle doğru tahminler sağlamaya yardımcı olabilecek meteorolojik değişkenleri tanımlayabilmek önemlidir. Sıcaklık, rüzgâr hızı, nem gibi hava koşullarına bağlı olarak günden güne değişen çıkış gücü üretimi doğrusal olmayan davranış sergiler. Başka bir deyişle, meteorolojik parametrelere bağlı bir modelin oluşturulması, FV sisteminin kararlılığının, güvenilirliğinin ve güvenliğinin iyileştirilmesine katkıda bulunacağı için önemlidir (Jebli ve ark., 2021).

Saray ve ark., (2011), tarafından yapay sinir ağı (YSA) yöntemini kullanılarak Amasya ilinin 2010 yılı yaz mevsimi için rüzgâr hızı tahmini yapılmış ve her bir ayın uygulaması için Hata Kareler Ortalamasının Karekökü (Root Mean Square Error: RMSE) ve Ortalama Kare Hatası (Mean Squared Error: MSE) değerleri hesaplanmıştır. Tahmin için YSA içerisinde çok katmanlı geri beslemeli ağ metodu ve Levenberg-Marquardt öğrenme algoritmaları kullanılmıştır. Sonuçta YSA'nın üç katmanlı ağ yapısı ile rüzgâr hızı tahmininde kullanılabileceği belirlenmiştir. Özcan ve ark., (2013), Isparta iline ait rüzgâr hızlarını uyarlamalı bulanık yapay sinir ağı çıkarım sistemi (ANFIS) ve YSA yöntemleriyle tahmin etmiştir. Meteoroloji İl Müdürlüğü'nden alınan Isparta iline ait, 1975 ve 2008 yılları arasındaki aylık rüzgar hızı verileri kullanılmıştır. YSA yöntemi kullanılarak yapılan tahminde tansig fonksiyonu kullanılarak en iyi sonucun LM12 algoritmasıyla olduğu belirlenmiştir. Çalışmanın sonucunda ANFIS yöntemiyle elde edilen R^2 değerinin YSA ile elde edilen değere nazaran daha yüksek olduğunu gözlemlemiştir. Doğancı ve ark., (2016), Meteoroloji İşleri Genel Müdürlüğü'nden alınan 2007-2014

yılları arasındaki yedi yıllık nem, sıcaklık, rüzgâr hızı, basınç ve yağış verilerini kullanarak YSA modeli ile rüzgâr hızını tahmin etmeye çalışmışlardır. Elde ettikleri tahmini verilerin gerçek değerlerle olan hata sapmalarını hesaplamışlardır. MSE istatistiksel yöntemi kullanarak rüzgâr hızı tahmininde elde ettikleri sonuçları gerçek verilerle karşılaştırmışlar ve MSE değerlerini, İnegöl bölgesi için 0.00176, Bafra bölgesi için 0.00088, Karabük bölgesi için 0.01392 ve Zonguldak bölgesi için 0.00257 olarak elde etmişlerdir. Kaya ve ark., (2016), Kastamonu ili rüzgâr gücü potansiyelini tahmin etmek için YSA ve ANFIS yöntemlerinde farklı rüzgâr türbin verileri kullanarak iki çeşit model oluşturmuşlardır. Güç tahmini için Meteoroloji Genel Müdürlüğü'nden alınan 2015 yılına ait Kastamonu ili günlük maksimum rüzgâr hızı verileri kullanılmıştır. Sonuç olarak, kullanılacak rüzgâr türbin modeline göre üretilebilecek maksimum güç değerleri tahmin edilmiştir. Güleç ve Demirel (2017), Devlet Meteoroloji İşleri Genel Müdürlüğü'nden alınan Kastamonu iline ait 2009- 2016 yılları arasında ölçülen aylık ortalama nispi nem, aylık ortalama sıcaklık, aylık açık gün sayısı, aylık ortalama hava basıncı, aylık ortalama rüzgâr hızı, aylık toplam güneşlenme süresi ve aylık toplam güneş ışınım şiddeti verilerinden yararlanarak YSA ile ileriye dönük güneş radyasyonunu tahmin etmişlerdir. Yaptıkları çalışmada, YSA yönteminin güneş radyasyon değerlerinin tahmininde başarılı şekilde kullanılabileceği görülmüştür. Dandil ve Gürgeç (2019), altı farklı açısız konuma yerleştirilen FV panel güç çıkışlarının aylık tahmini için, akım ve gerilim değerlerini kullanarak farklı algoritmalar ile öğrenebilen YSA modeli önermişlerdir. Çalışmalarında, Bilecik Şeyh Edebali Üniversitesi yerleşkesinde kurulu olan FV panel test düzeneğinden elde edilen verileri kullanmışlardır. Hesaplamalarda parçacık sürü optimizasyonu (PSO) algoritmasına dayalı YSA ile geriye yayılım (GY) ve diğer optimizasyon algoritması Klonal Seçim Algoritması (KSA) ile eğitilen modellerden faydalanılmıştır. Elde edilen doğrulama sonuçları incelendiğinde, hemen hemen bütün aylar için PSO algoritması ile eğitilen YSA yapısının, GY ve KSA algoritmaları ile eğitilen YSA yapısına göre daha başarılı sonuçlar verdiği gözlenmiştir. Gabralı ve Aslan (2020), İstanbul İli Büyükçekmece İçerisinde bulunan Tarım ve Orman Bakanlığına bağlı Tarım Bilgi Sistemi Eskice Mevki istasyonundan alınan 2016 yılına ait güneş radyasyonu, toprak üstü sıcaklık, rüzgâr yönü, rüzgâr şiddeti vb. verilerini kullanarak güneş radyasyonu için ileriye dönük kısa ve orta vadeli tahmin çalışması yapmışlardır. Modellemede Çoklu Lineer Regresyon (ÇLR) ile YSA kullanmışlardır. Sonuçlar karşılaştırıldığında, güneş radyasyonu tahmininde YSA sonuçlarının ÇLR sonuçlarından daha başarılı olduğunu gözlemlemişlerdir. YSA modelinde güneş radyasyonu için R^2 , normalize Hata Kareler Ortalamasının Karekökü (nRMSE) ve ortalama mutlak yüzde hata (MAPE) değerlerini sırasıyla 0.912, %48.5, %28.21 olarak hesaplamışlardır.

Bu çalışma, makine öğrenme tekniklerine dayalı olarak güneş enerjisini tahmin etmek için bir yaklaşım sunmaktadır. Çalışmada, Amasya Üniversitesi İpekköy yerleşkesinde kurulu 200 kW güneş enerji santrali üretim verilerinin, meteorolojik verilere bağlı olarak çok katmanlı yapay sinir ağı (ÇKYSA) ve uyarlamalı bulanık yapay sinir ağı çıkarım sistemi (ANFIS) yardımıyla tahmini yapılmıştır. HOBOLINK uzaktan izleme sistemi tarafından kaydedilen rüzgâr yönü, rüzgâr hamlesi, rüzgâr hızı, güneş radyasyonu, panel sıcaklığı, hava sıcaklığı, nem, çiy noktası, basınç ve batarya gerilimi değerleri

makine öğrenmesi modelleri için özellik (girdi) olarak kullanılmıştır. Algoritma tarafından öngörülecek çıkış parametresi santralde bulunan eviricilerin çıkış enerjileridir. Elde edilen tahmin algoritmalarının sonuçları karşılaştırılmıştır.

2. Materyal ve Metot

2.1. Veri Kümesi ve Özellikler

Bu çalışmada, Amasya Üniversitesi İpekköy yerleşkesinde kurulu 200kW güneş enerji santralinin üretim verileri kullanılmıştır. HOBOLINK, sistemleri uzaktan izlemek için kullanılan web tabanlı bir yazılımdır. Bu yazılım birçok iklimsel veriyi ve üretim bilgilerini kaydederek uzaktan izlenmesini sağlar. Sistemde rüzgâr yönü, rüzgâr hamlesi, rüzgâr hızı, güneş radyasyonu, panel sıcaklığı, hava sıcaklığı, havadaki nem, çiy noktası, hava basıncı ve batarya gerilimi değerleri HOBOLINK uzaktan izleme sistemi tarafından kaydedilmiştir. Bu değişkenler 5 dakikalık periyotlarda ölçülerek kayıt altına alınmıştır. Bu çalışmada gerçekleştirilen analizlerde 15 dakikalık periyotlarda elde edilen ölçüm sonuçları ve bu anlarda 10 evirici çıkışındaki enerjileri kullanılmıştır. HOBOLINK iklim parametreleri için yapılan ölçümlere ait örnekler Tablo 1’de verilmiştir.

Tablo 1. Ölçüm istasyonu kayıt sistemi örnek değerleri

Tarih Saat	Rüzgar Yönü [°]	Rüzgar Hızı [m/s]	Rüzgar Hamlesi [m/s]	Güneş Radyasyonu [W/m ²]	Panel Sıcaklığı [°C]	Hava Basıncı [mBar]	Hava Sıcaklığı [°C]	Hava Nemi [%]	Çiy Noktası [°C]	Batarya Gerilimi [V]
1/1/16 11:00:00	190	0.8	2.3	493	8.79	971.5	-1.58	62.3	-7.85	4.57
1/1/16 11:05:00	211	1.5	3.5	353	8.94	972.2	-2.74	65.1	-8.38	4.57
1/1/16 11:10:00	223	1.5	3.3	283	8.07	972.5	-2.68	65.1	-8.33	4.56
1/1/16 11:15:00	225	0.8	2.8	336	8.47	972.2	-2.04	64.6	-7.82	4.57
1/1/16 11:20:00	208	0.3	1.8	251	7.82	972.5	-1.53	63	-7.65	4.57
1/1/16 11:25:00	181	0.5	2.8	279	5.51	972.1	-1.67	62.8	-7.83	4.57
1/1/16 11:30:00	159	0.5	2	311	4.82	972.1	-1.64	62.1	-7.94	4.57
1/1/16 11:35:00	180	0.8	2.5	463	6.53	971.5	-1.24	61.5	-7.69	4.57
1/1/16 11:40:00	192	1.3	3.3	438	6.86	971.3	-1.24	60.4	-7.92	4.57
1/1/16 11:45:00	216	1	2.8	447	8	971.2	-0.96	58.7	-8.02	4.56

Santralde toplam 10 evirici bulunmaktadır. Evirici çıkış enerjileri de HOBOLINK uzaktan izleme sistemi tarafından kaydedilmiştir. 10 eviriciye ait kaydedilmiş olan çıkış enerjileri Tablo 2’de verilmiştir.

Tablo 2. Evirici çıkış enerjileri için örnek değerler

Tarih Saat	Evirici1 [kWhAC l]	Evirici2 [kWhAC l]	Evirici3 [kWhAC l]	Evirici4 [kWhAC l]	Evirici5 [kWhAC l]	Evirici6 [kWhAC l]	Evirici7 [kWhAC l]	Evirici8 [kWhAC l]	Evirici9 [kWhAC l]	Evirici10 [kWhAC l]
10/01/2016 07:15:00	0	0	0	0	0	0	0	0	0	0
10/01/2016 07:30:00	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0	0
10/01/2016 07:45:00	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1
10/01/2016 08:00:00	0.4	0.4	0.4	0.5	0.8	0.5	0.5	0.4	0.3	0.3
10/01/2016 08:15:00	0.7	0.7	0.5	0.7	1.1	0.6	0.6	0.5	0.4	0.5
10/01/2016 08:30:00	0.9	0.9	0.6	0.8	1.3	0.9	0.9	0.8	0.8	0.5
10/01/2016 08:45:00	1.7	1.7	0.9	1.2	2	1.1	1.1	1.1	1.3	0.9
10/01/2016 09:00:00	1.9	1.9	0.9	1.1	1.7	1.1	1.1	1	1.5	1
10/01/2016 09:15:00	2.1	2.1	0.9	0.9	2	1.2	1.2	1.2	1.6	1.1
10/01/2016 09:30:00	2.4	2.4	1.2	1.6	2.1	1.3	1.3	1.3	1.8	1.2

Çalışmada güneş enerjisi üretim verilerinin tahmini için kullanılan özellikler Tablo 3'te verilmiştir.

Tablo 3. Santral üretim tahmini için kullanılan özellikler

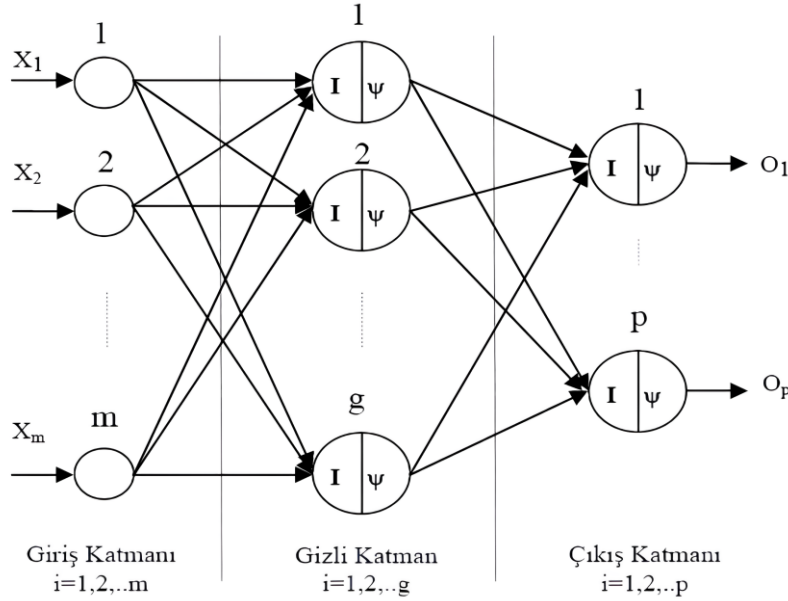
Özellikler	
1. özellik	Ay
2. özellik	Gün
3. özellik	Saat
4. özellik	Rüzgâr yönü (°)
5. özellik	Rüzgâr hızı (m/s)
6. özellik	Rüzgâr hamlesi(m/s)
7. özellik	Güneş radyasyonu (W/m ²)
8. özellik	Hava basıncı (mbar)
9. özellik	Hava sıcaklığı (°C)
10. özellik	Nispi nem (%)
11. özellik	Çiy noktası (°C)
12. özellik	Batarya gerilimi (V)

2.2. Yapay Sinir Ağları (YSA)

YSA, insan beyninin yapısı esas alınarak geliştirilmiş bir sistemdir. YSA'lar, çok sayıda işlem birimini kendi kendine uyum sağlama, kendi kendini organize etme ve gerçek zamanlı öğrenme gibi bir dizi özellik ile birleştiren uyarlanabilir doğrusal olmayan bilgi işleme sistemleridir. YSA'ların avantajları esas olarak ağ mimarisi ve algoritmalar tarafından temsil edilmesidir. Bir YSA, nöronlar olarak da

adlandırılan bir dizi işlem biriminden oluşur ve bunlar birbirine bağlıdır. Yönlendirilmiş bir grafik olarak tanımlanabilir ve her nöron bir transfer fonksiyonudur. Bir nöron genellikle çok girişli ve tek çıkışlı doğrusal olmayan bir elemandır. Bir sinir ağının mimarisi, ağın tüm bağlantıları ve nöronların transfer fonksiyonları tarafından belirlenir (Ding ve ark., 2013; Özcan ve ark., 2013; Şahan ve Yüksel, 2016; Abiodun ve ark., 2018; Şahan, 2021).

Çok katmanlı yapay sinir ağı, bir özellik (giriş) kümesi ile buna karşılık hedef (çıkış) değerleri arasında doğrusal olmayan bir eşlemeyi temsil eden bir modeldir. Çok katmanlı yapay sinir ağı, denetimli öğrenme metodunu kullanmaktadır. Girişler ve bu girişlerin karşılığındaki hedef çıkışlar ağı verilmektedir. ÇKYSA, Şekil 1 de gösterildiği gibi basit birbirine bağlı nöronlar veya düğümler sisteminden oluşur. Düğümler, basit bir doğrusal olmayan aktivasyon fonksiyonu tarafından değiştirilen, düğüme girişlerin toplamının bir fonksiyonu olan ağırlıklar ve çıkış sinyalleri ile bağlanır. Giriş katmanında veri kümesindeki özellik sayısı kadar nöron bulunur. Giriş katmanı uygulanan veri kümesini değişikliğe uğratmadan gizli katmana iletir. ÇKYSA, bir veya daha fazla gizli katman ve son olarak bir çıkış katmanı içermektedir. ÇKYSA, eğitim yoluyla öğrenme yeteneğine sahiptir (Gardner ve Dorling, 1998; Oral, 2011; Var ve Türkay, 2014).




Şekil 1. ÇKYSA ağ mimarisi (Oral, 2011)

2.3. Uyarlamalı Bulanık Yapay Sinir Ağı Çıkarım Sistemi (ANFIS)

ANFIS (Adaptive Neuro Fuzzy Inference System); YSA ile bulanık mantığın bir arada kullanıldığı sistemdir. ANFIS, ileri beslemeli bir sinir ağının düğümlerinin bulanık parametreleri işlediği hibrit bir sistemdir. ANFIS modeli, bulanıklaştırma adı verilen bir süreçte girdi üyelik fonksiyonlarını kullanarak girdi özelliklerini üyelik değerlerine dönüştürdüğü birinci dereceden Sugeno çıkarım sistemlerine eşdeğerdir. Ardından, model çıktısını anlamak için bir dizi mantıksal kurallar kullanılır. Daha sonra,

çıkartım çıktısını gerçek değerler çıktısına durulaştırmak için çıktı üyelik fonksiyonları kümesi kullanılır. Bu algoritma, girdi verilerini ayırmak için girdi üyelik fonksiyonlarını ve bulanık parametreleri ayarlamak için sinir ağlarının geri yayılım özelliğine benzer hata optimizasyon algoritmaları kullanır. ANFIS'in eğitimi, yapısındaki parametreleri bir optimizasyon algoritması kullanılarak belirlenmesi anlamına gelir. Genel ANFIS mimarisi Şekil 2'de gösterildiği gibi 5 katmandan oluşur. Her katman, bir matematiksel işlem gerçekleştirir (Gökçe ve Sonugür, 2016; Karaboga ve Kaya, 2019; Zaghoul ve ark., 2020).



Şekil 2. ANFIS modeli (Karaboga ve Kaya, 2019; Zaghoul ve ark., 2020)

ANFIS, üyelik fonksiyonu parametrelerini ve sonuç parametrelerini tahmin etmek için optimizasyon algoritmalarına ihtiyaç duyar. Geri yayılım, çıktı katmanındaki hatayı hesaplar ve bunu parametre ayarlaması için girdi katmanına geriye doğru yayar. Bu algoritma yerel minimumda sıkışabilir ve yavaş bir performansa sahiptir. Hibrit optimizasyon, gradyan iniş ve en küçük kareler optimizasyon yöntemlerini birleştirerek daha hızlı performansa sahip ve yerel minimum tuzağından kaçınan alternatif bir optimizasyon algoritmasıdır (Gökçe ve Sonugür, 2016; Karaboga ve Kaya, 2019; Zaghoul ve ark., 2020).

3. Bulgular ve Tartışma

Çalışmada, Amasya Üniversitesi İpekköy yerleşkesinde kurulu 200kW güneş enerji santralinin 4 Ocak 2016 ve 20 Eylül 2016 tarihlerinde ölçülen üretim verileri kullanılmıştır. HOBOLINK uzaktan izleme sistemi tarafından kaydedilen rüzgâr yönü, rüzgâr hamlesi, rüzgâr hızı, güneş radyasyonu, panel sıcaklığı, hava sıcaklığı, nem, çiy noktası, hava basıncı ve batarya gerilimi değerleri ve 10 evirici çıkış enerjileri kullanılmıştır. Çalışmada gerçekleştirilen analizlerde 15 dakikalık periyotlarda gerçekleştirilen ölçüm sonuçları ve bu anlarda 10 evirici çıkışındaki enerji değerlerinin ortalaması kullanılmıştır.

Özellik veri kümesinde 12 özellik ve 24356 örnek bulunmaktadır. Ay, gün, saat, rüzgâr yönü, rüzgâr hamlesi, rüzgâr hızı, güneş radyasyonu, panel sıcaklığı, hava sıcaklığı, nem, çiy noktası, basınç ve batarya gerilimi değerleri özellik kümesini oluşturmaktadır. Çıkış tahmini için öncelikle 10 eviriciye ait çıkış enerjileri kullanılmıştır. Daha sonra işlem karmaşıklığını azaltmak ve tahmin algoritmasının

başarımını iyileştirmek için 10 eviricin çıkış enerjilerinin ortalaması hesaplanmıştır. Çıkış kümesi evirici enerjilerinin ortalamasını içermektedir.

ÇKYSA ve ANFIS yöntemleriyle analiz gerçekleştirilerek çıkış enerjisi tahmini yapılmıştır. MATLAB programı kullanılarak bütün analizler gerçekleştirilmiştir. Başarım sonuçlarının değerlendirilmesi için korelasyon katsayısı karesi (R^2), ortalama karesel hata (MSE) ve kök ortalama karesel hata (RMSE) değerleri hesaplanmıştır. R^2 , ölçülen gerçek değerler ile tahmin edilen değerlerin birbirlerine hangi derecede bağlı oldukları, aralarında doğrusal bir ilişkinin bulunup bulunmadığını tespit etmede kullanılan test yöntemidir. RMSE değeri, ağı tahmin ettiği değerlerin ölçüm değerlerinden ne oranda saptığının ölçüsüdür. MSE değeri, ne kadar sıfıra yakın bir değer olursa oluşturulan modelin o denli başarılı sayılması beklenir (Şahan ve Yüksel, 2016; Jebli ve ark.,2021; Şahan, 2021).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2} \quad (1)$$

$$MSE = \frac{\sum_{i=1}^n (y_i - x_i)^2}{n} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}} \quad (3)$$

Eşitliklerde belirtilen y_i tahmin edilen değeri, x_i gerçek değeri, \bar{x}_i gerçek değer ortalamasını ifade ederken, n ise veri sayısını göstermektedir.

3.1. ÇKYSA Uygulaması

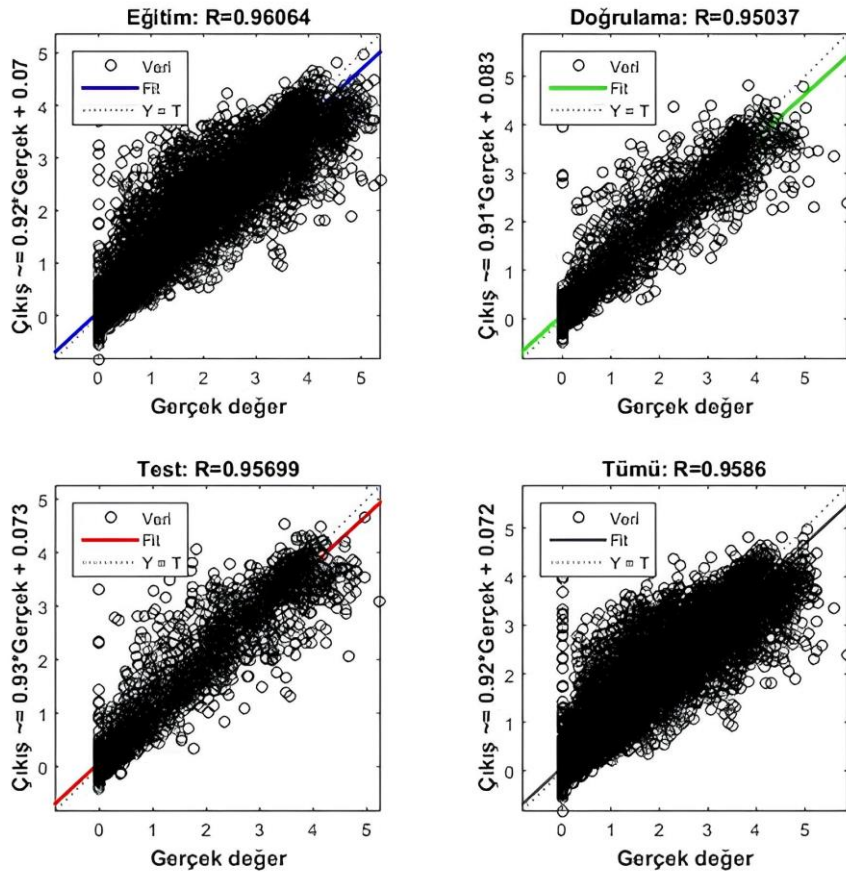
Çalışmanın bu kısmında çok katmanlı ileri beslemeli yapay sinir ağı algoritması kullanılmıştır. Farklı öğrenme algoritmaları seçilerek ve gizli katmandaki nöron sayısı değiştirilerek farklı modeller denenmiş ve sonuçlar karşılaştırılmıştır. ÇKYSA modeli, 12 girdi değişkeni (ay, gün, saat, rüzgâr yönü, rüzgâr hamlesi, rüzgâr hızı, güneş radyasyonu, panel sıcaklığı, hava sıcaklığı, nem, çiy noktası, basınç ve batarya gerilimi) ve bir çıktı değişkenine (evirici ortalama enerjisi) göre tasarlanmıştır. Veri kümesinin (24356 örnek); %70'i (17050 örnek) eğitim, %15'i (3653 örnek) doğrulama ve %15'i (3653 örnek) test için kullanılmıştır. Model bir giriş katmanı, bir gizli katman ve bir çıkış katmanından oluşmaktadır. Gizli katman nöron sayısı 50 seçildiğinde elde edilen başarım sonuçları Tablo 4'te verilmiştir.

Tablo 4. ÇKYSA başarım sonuçları

	Örnek	MSE	RMSE	R^2
Eğitim	17050	0.1342	0.3663	0.9606
Doğrulama	3653	0.1634	0.4042	0.9503
Test	3653	0.1434	0.3786	0.9569

YSA’larda nöronların ağırlıkları eğitim iterasyonları süresince belirli öğrenme kurallarına göre güncellenmektedir. Değişik öğrenme algoritmaları verilerin kendilerine has yapıları nedeniyle farklı tahmin başarımları ortaya koyabilmektedir. Bu çalışmada literatürde sık rastlanan Levenberg-Marquardt (“trainlm”) ile Scaled Conjugate Gradient-Ölçenikli Eşlenik Gradyan Geri Yayılım Algoritması (“trainscg”) eğitim algoritmaları seçilerek ayrı ayrı denenmiştir. Gizli katman aktivasyon fonksiyonu “sigmoid” ve çıkış katmanı aktivasyon fonksiyonu “lineer” olarak alınmıştır. Yapılan denemelerde epoch sayısı 1000 olarak kullanılmıştır. Her bir ağ için en uygun değer elde edebilmek maksadıyla 10’ar defa çalıştırılmıştır.

Şekil 3, gerçek çıkış enerjisi değerleri ve tahmin edilen çıkış enerjisi değerleri için ÇKYSA modelinin eğitim, doğrulama, test ve tüm değerleri arasındaki ilişkiyi göstermektedir. Eğitim verilerindeki başarı oranı $R^2 = 0.96064$, doğrulama verilerindeki başarı oranı $R^2 = 0.95037$ iken test verilerindeki başarı oranı $R^2 = 0.95699$ olarak bulunmuştur. Oluşturulan ağın, verilerin tümü için oranı ise $R^2 = 0.9586$ ’dır. Bu oran ağın gayet başarılı olduğunu göstermektedir. Sonuçlar incelendiğinde oluşturulan modelin başarılı olduğu görülmektedir. Sonuçlar, gerçek değerler ile tahmin edilen değerler arasındaki korelasyonun, tüm verilerde güçlü olduğunu göstermektedir.



Şekil 3. ÇKYSA tahmin sonuçları


Farklı öğrenme algoritmaları ve farklı gizli katman nöron sayısı seçilerek elde edilen ÇKYSA modelinin tahmin sonuçları aşağıda Tablo 5’te verilmiştir.

Tablo 5. Farklı öğrenme algoritmaları ve farklı gizli katman nöron sayıları için ÇKYSA modelin başarımları sonuçları

Eğitim Algoritması	Nöron Sayısı	Eğitim			Doğrulama			Test		
		MSE	RMSE	R ²	MSE	RMSE	R ²	MSE	RMSE	R ²
Trainlm	n = 8	0.1859	0.4311	0.9444	0.2090	0.4571	0.9377	0.1954	0.4420	0.9426
	n = 10	0.1687	0.4107	0.9495	0.1816	0.4261	0.9468	0.1918	0.4379	0.9435
	n = 11	0.1760	0.4195	0.9482	0.1690	0.4110	0.9452	0.1752	0.4185	0.9495
	n = 12	0.1697	0.4119	0.9491	0.1687	0.4107	0.9500	0.1604	0.4004	0.9542
	n = 13	0.1634	0.4042	0.9513	0.1592	0.3989	0.9528	0.1688	0.4108	0.9504
	n = 20	0.1533	0.3915	0.9537	0.1575	0.3968	0.9555	0.1582	0.3977	0.9545
	n = 50	0.1342	0.3663	0.9606	0.1634	0.4042	0.9503	0.1434	0.3786	0.9569
Trainseg	n = 8	0.2141	0.4627	0.9360	0.2070	0.4549	0.9389	0.2076	0.4556	0.9369
	n = 10	0.2241	0.4733	0.9329	0.2253	0.4746	0.9324	0.2285	0.4780	0.9311
	n = 11	0.2132	0.4617	0.9360	0.1946	0.4411	0.9401	0.2220	0.4711	0.9360
	n = 12	0.1948	0.4413	0.9417	0.2121	0.4605	0.9380	0.2034	0.4509	0.9386
	n = 13	0.2269	0.4763	0.9331	0.2224	0.4715	0.9305	0.2054	0.4532	0.9357
	n = 20	0.2228	0.4720	0.9328	0.2194	0.4684	0.9360	0.2210	0.4701	0.9343
	n = 50	0.2463	0.4962	0.9262	0.2426	0.4925	0.9287	0.2282	0.4777	0.9285

Tablo 5’te verilen başarımları sonuçları değerlendirildiğinde “trainlm” eğitim algoritmasının daha başarılı olduğu tespit edilmiştir. Aynı zamanda gösterilen algoritmalarından gizli katman sayısı 50 olarak seçildiğinde, ağırlık eğitim aşamasında R² değerinin 0.9606 ve MSE değerinin 0.1342, test aşamasında R² değerinin 0.9569 ve MSE değerinin 0.1434, doğrulama aşamasında ise R² değerinin 0.9503 ve MSE değerinin 0.1634 olduğu görülmektedir. Ayrıca gizli katmanda nöron sayısı değişiminin tahmin performansını etkilediği gözlenmiştir.

Şekilde 4’te veri setindeki gerçek değerler ile tahmin edilen değerlerin ne oranda çakıştığı görülmektedir. Şekil 4 incelendiğinde gerçek değerler ile tahmin edilen değerlerin birbirine yakın olduğu görülmektedir.



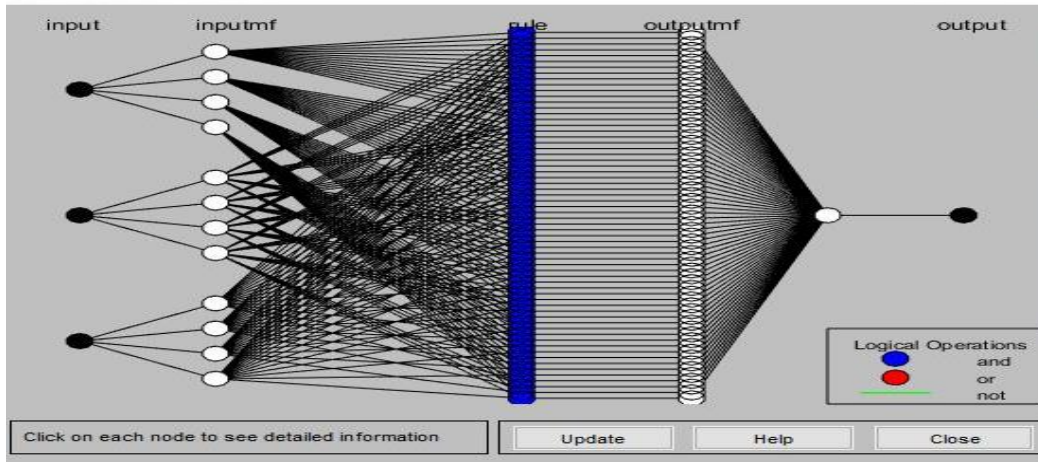
Şekil 4. ÇKYSA modeli için gerçek ve tahmin edilen sonuçlar

3.2. ANFIS Uygulaması

Çalışmanın bu bölümünde ANFIS algoritması kullanılmıştır. Özelliklerin boyutunun fazla olması ANFIS uygulamasında hesaplama karmaşıklığını artırmaktadır. Bu nedenle temel bileşenler analizi kullanılarak boyut azaltımı gerçekleştirilmiştir. Bu uygulamada, temel bileşenler analizi ile boyut indirgeme işlemi sağlanarak güneş enerjisi santrali çıkış enerjisine etki eden 12 özellik 3 özelliğe indirilmiştir. Bir başka deyişle, problem üç girdi ve bir çıktıdan oluşan sisteme dönüştürülmüştür.

Veri kümesinde, temel bileşenler analizi ile boyut indirgeme işleminden sonra veriler [0,1] aralığında normalize edilmiştir. Ağı eğitmek için kullanılan eğitim veri seti tüm verilerin yaklaşık %70'i olan 17050 veri seti, test için tüm veri setinin yaklaşık %23'ü olarak 5601 veri seti ve kontrol veri seti için de tüm setin %7'si olarak 1705 veri setine ayrılarak üç ayrı dosya olarak kaydedilip modele yüklenmiştir. Veri setinin eğitim, test ve kontrol olarak üç parçaya ayrılması için basit rassal ayırım yöntemi kullanılmıştır. Girdi ve çıktı verileri arasındaki ilişki model içerisinde bulunan 8 adet üyelik fonksiyonu kullanılarak sistemin eğitilmesi sağlanmıştır. Üyelik fonksiyonu olarak melez algoritması uygulanmış ve hata oranları gözlemlenerek sonuçlar elde edilmiştir. Melez algoritma, geri yayılım algoritması ile en küçük kareler yönteminin beraber kullanıldığı öğrenme algoritmasıdır. Üyelik fonksiyonları seçildikten sonra eğitim döngü (epoch) sayısı belirlenmiştir. Gözlemler sonucunda

modelin 50 devir sonrası durduđu anlaşıldığından eğitim döngü değeri 50 olarak belirlenmiştir. Eğitim döngü değeri belirlendikten sonraki aşamada, eğitimler sırasıyla başlatılarak sonuçlar elde edilmiştir. Bu uygulamada, birkaç üyelik fonksiyon sayısı, tüm üyelik fonksiyon tipleri ile çıktı tipi constant/linear için sırasıyla denenmiştir, Şekil 5'te oluşturulan ANFIS modelinin yapısı görülmektedir. İlk aşamada üç bağımsız değişken girdi olarak sisteme girilmiştir. İkinci aşamada ise girdi değerleri 4-4-4 üyelik fonksiyonuna belirli bir üyelik derecesinde model tarafından atanmıştır. Sonraki sütunda ise üyelik fonksiyonları kullanılarak elde edilen 64 kural yer almaktadır. Bulanık ağı en iyi şekilde öğrenmeyi gerçekleştireceği 64 kural belirlemiş ve her kuraldan bir değer üretmiştir. Oluşturulan çıktı üyelik fonksiyon değerleri tek çıktı değerine dönüştürülmüştür.



Şekil 5. ANFIS modeli ağ yapısı


Tablo 6'da sonuçların incelenmesinde en başarılı sonucun 0.0946 hata oranıyla, melez algoritma ve gbellmf üyelik fonksiyon tipi ile girdi değerleri için 4-4-4 üyelik fonksiyonun birlikte kullanıldığı modelin ürettiği gözlemlenmektedir. Ayrıca tablodan anlaşıldığı gibi çıktı üyelik fonksiyon tipi sabit (constant) olmalıdır.

Tablo 6. 4-4-4 üyelik fonksiyon sayısı deneme sonuçlarına ilişkin başarımların sonuçları


Sabit		Eğitim			Test			Kontrol		
Fonksiyon Tipi	Üyelik Fonksiyon Sayısı	MSE	RMSE	R ²	MSE	RMSE	R ²	MSE	RMSE	R ²
trimf	4-4-4	0.0082	0.0904	0.9068	0.0092	0.0957	0.9268	0.0161	0.1270	0.9099
trapmf	4-4-4	0.0083	0.0908	0.9058	0.0095	0.0972	0.9234	0.0179	0.1340	0.8976
gbellmf	4-4-4	0.0081	0.0899	0.9079	0.0089	0.0946	0.9294	0.0163	0.1278	0.9175
gaussmf	4-4-4	0.0081	0.0901	0.9073	0.0090	0.0948	0.9293	0.0174	0.1317	0.9139
gauss2mf	4-4-4	0.0081	0.0900	0.9075	0.0095	0.0975	0.9247	0.0217	0.1472	0.8776
pimf	4-4-4	0.0082	0.0904	0.9067	0.0093	0.0965	0.9252	0.0167	0.1292	0.9057
dsigmf	4-4-4	0.0081	0.0901	0.9073	0.0091	0.0956	0.9269	0.0161	0.1270	0.9115
psigmf	4-4-4	0.0081	0.0901	0.9073	0.0091	0.0956	0.9269	0.0161	0.1270	0.9115
Doğrusal		Eğitim			Test			Kontrol		
trimf	4-4-4	0.0078	0.0884	0.9109	0.0096	0.0977	0.9246	0.0209	0.1446	0.8925
trapmf	4-4-4	0.0077	0.0876	0.9126	0.0116	0.1076	0.9058	0.0228	0.1511	0.8583
gbellmf	4-4-4	0.0073	0.0856	0.9167	0.0104	0.1022	0.9162	0.0228	0.1510	0.8582
gaussmf	4-4-4	0.0074	0.0858	0.9165	0.0110	0.1049	0.9107	0.0237	0.1538	0.8458
gauss2mf	4-4-4	0.0073	0.0857	0.9166	0.0118	0.1085	0.9054	0.0233	0.1527	0.8586
pimf	4-4-4	0.0076	0.0870	0.9139	0.0181	0.1344	0.8525	0.0416	0.2040	0.7407
dsigmf	4-4-4	0.0074	0.0860	0.9159	0.0124	0.1114	0.8998	0.0293	0.1712	0.8184
psigmf	4-4-4	0.0074	0.0860	0.9159	0.0124	0.1114	0.8998	0.0293	0.1712	0.8184

Elde edilen sonuçlar baz alınarak en iyi sonucu üreten üyelik fonksiyon tipi ve fonksiyon sayısı gbellmf (4-4-4) kullanılarak ağı eğitilmesi sonucunda ağı eğitim hatası RMSE = 0.0899, test hatası RMSE = 0.0946 ve kontrol hatası RMSE = 0.1278 olarak bulunmuştur.


Eğitim, test ve kontrol veri setlerindeki gerçek değerler ile tahmin edilen değerlerinin ne oranda çakıştığı Şekil 6, Şekil 7 ve Şekil 8’de görülmektedir.



Şekil 6. ANFIS uygulaması eğitim veri seti için gerçek değerler ve tahmini sonuçlar



Şekil 7. ANFIS uygulaması test veri seti için gerçek değerler ve tahmini sonuçlar



Şekil 8. ANFIS uygulaması kontrol veri seti için gerçek değerler ve tahmini sonuçlar

ÇKYSA ve ANFIS kullanarak güneş enerjisi santrali çıkış enerjisi tahminlerinden elde edilen performans sonuçları Tablo 7’de verilmiştir. Tabloda YSA’nın R^2 değeri büyük olmasına rağmen MSE ve RMSE değerinin de büyük olmasının nedeni ANFIS uygulamasında verinin normalize edilmesinden dolayıdır.

Tablo 7. ANFIS ve ÇKYSA yöntemleri için başarımları

Yöntem	R^2	MSE	RMSE
ANFIS	0.9294	0.0089	0.0946
YSA	0.9569	0.1434	0.3786

4. Sonuç

Bu çalışmada, meteorolojik verilere bağlı olarak bir güneş enerji santrali üretim enerjisi tahmini için makine öğrenme tekniklerine dayalı bir yaklaşım sunulmuştur. Çalışmada kullanılan veriler Amasya Üniversitesi İpekköy yerleşkesinde kurulu 200kW güneş enerji santrali üretim verileridir. Tahmin algoritması olarak ÇKYSA ve ANFIS yöntemleri kullanılmıştır. Algoritma sonuçlarının karşılaştırmalı analizi yapılmıştır.

ÇKYSA metodu kullanılarak yapılan tahminde en iyi sonucun Levenberg-Marquardt (trainlm) algoritmasıyla elde edildiği belirlenmiştir. ANFIS metodu kullanılarak yapılan tahminde ise en başarılı sonucun melez algoritma ve gbellmf üyelik fonksiyon tipi ile girdi değerleri için 4-4-4 üyelik

fonksiyonun birlikte kullanıldığı modelin ürettiği belirlenmiştir. ÇKYSA uygulaması sonucunda R^2 değeri 0.9569, MSE değeri 0.1434 ve RMSE değeri 0.3786 olarak elde edilmiştir. ANFIS uygulaması sonucunda R^2 , MSE ve RMSE değerleri sırasıyla 0.9294, 0.0089 ve 0.0946 olarak hesaplanmıştır. Oluşturulan ÇKYSA ve ANFIS modelleriyle yapılan tahmin değerlerinin ölçülen değerler ile makul düzeyde yakınsadığı saçılma grafiklerinden görülmüştür. R^2 değeri açısından ÇKYSA, ANFIS metoduna göre daha başarılı performans göstermektedir.

Bu çalışma ile güneş enerjisi santrali çıkış enerjisinin tahmininde ÇKYSA ve ANFIS modellerinin kullanılabilmesi ancak ÇKYSA'nın daha iyi performans gösterdiği belirlenmiştir. Test sonuçları incelendiğinde modellerin yaptıkları tahmin değerlerinin tutarlı ve güvenilir olduğu tespit edilmiştir. Farklı jeolojik konumlarda yer alan santraller veya diğer enerji santrallerinde de üretim verileri aynı metodlarla hesaplanabilir.

Çıkar Çatışması Beyanı

Makale yazarları herhangi bir çıkar çatışması olmadığını beyan eder. Bu araştırma Serdar SOMUNCU'nun Dr. Öğr. Üyesi Canan ORAL danışmanlığında Yüksek Lisans Tezi'nin bir kısmından hazırlanmıştır.

Araştırmacıların Katkı Oranı Beyan Özeti

Yazarlar makaleye eşit oranda katkı sağlamıştır.

Kaynakça

- Abiodun OI., Jantan A., Omolara AE., Dada KV., Mohamed NA., Arshad H. State-of-the-art in artificial neural network applications: A survey. *Heliyon* 2018; 4(11): 1-41. e00938.
- Dandıl E., Gürgen E. Yapay sinir ağları kullanılarak fotovoltaik panel güç çıkışlarının tahmini ve sezgisel algoritmalar ile karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi* 2019; 16: 146-158.
- Ding S., Li H., Su C., Yu J., Jin F. Evolutionary artificial neural networks: a review. *Artificial Intelligence Review* 2013; 39(3): 251-260.
- Doğancı Ö., Ertürk M., Özsunar A., Arcaklıoğlu E. Orta ve Batı Karadeniz Bölgesi rüzgâr enerjisi tahmin çalışması. *İleri Teknoloji Bilimleri Dergisi* 2016; 5(1): 153-163.
- Gabralı D., Aslan Z. Güneş enerjisi potansiyelinin çoklu lineer regresyon ve yapay sinir ağları ile modellenmesi. *Aurum Mühendislik Sistemleri ve Mimarlık Dergisi* 2020; 4(1): 23-36.
- Gardner MW., Dorling SR. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment* 1998; 32(14/15): 2627-2636.
- Gökçe B., Sonugür G. ANFIS ve YSA yöntemleri ile işlenmiş doğal taş üretim sürecinde verimlilik analizi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi* 2016; 16(1): 174-185.
- Güleç GH., Demirel H. Meteorolojik veriler kullanılarak Kastamonu ili güneşlenme şiddetinin yapay sinir ağları ile tahmini. *Technological Applied Sciences* 2017; 12(3): 114-121.

- Jebli I., Belouadha FZ., Kabbaj MI., Tilioua A. Prediction of solar energy guided by pearson correlation using machine learning. *Energy* 2021; 224(2021): 120109.
- Karaboga D., Kaya E. Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey. *Artificial Intelligence Review* 2019; 52(4): 2263-2293.
- Kaya Ü., Caner M., Oğuz Y. Rüzgâr türbin modelleri kullanarak Kastamonu ili rüzgâr ile elektrik üretim potansiyeli tahmini. *Technological Applied Sciences* 2016; 11(3): 65-74.
- Oral C. Sayısal mamografi görüntülerine yapay zekâ yöntemlerinin uygulanması. Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, syf no: 118, Samsun, Türkiye, 2011.
- Özcan İ., Şahin ŞA., Dikmen E., Bayram G. Isparta ilinde rüzgâr hızı değerlerinin belirlenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 2013; 17(1): 109-112.
- Saray U., Lüy M., Çam E. Amasya ili için yapay sinir ağlarıyla rüzgar hızı tahmini. *Elektrik Elektronik Mühendisliği Günleri Bildiriler Kitabı*, 29 Eylül-1 Ekim 2011, sayfa no: 20-24, Ankara.
- Şahan M., Yüksel O. Akdeniz bölgesine ait meteorolojik veriler kullanılarak yapay sinir ağları yardımıyla güneş enerjisinin tahmini. *Süleyman Demirel University Faculty of Arts and Science Journal of Science* 2016; 11(1): 61-71.
- Şahan M., Yapay sinir ağları ve angström-prescott denklemleri kullanılarak Gaziantep, Antakya ve Kahramanmaraş için global güneş radyasyonu tahmini, *Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Fen Dergisi*, 2021,; 16(2): 368-384
- Var H., Türkay BE. Yapay sinir ağları kullanılarak kısa dönem elektrik yükü tahmini. *Elektrik–Elektronik, Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*, 27-29 Kasım 2014, sayfa no:34-37, Bursa.
- Zaghloul MS., Hamza RA., Iorhemen OT., Tay JH. Comparison of adaptive neuro-fuzzy inference systems (ANFIS) and support vector regression (SVR) for data-driven modelling of aerobic granular sludge reactors. *Journal of Environmental Chemical Engineering* 2020; 8(3): 103742.