

## Farklı Yapay Sinir Ağları Yöntemlerini Deneysel Olarak Ölçülen Güneş Işınım Tahminine Etkisi

Enes YILDIZ<sup>1\*</sup>, Fatih SERTTAŞ<sup>2</sup>

<sup>1</sup>Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, Afyonkarahisar.

<sup>2</sup>Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, Afyonkarahisar.

Sorumlu yazar e-posta\*: enesyildiz@aku.edu.tr

ORCID ID: <http://orcid.org/0000-0001-9116-4980>

fserttas@aku.edu.tr

ORCID ID: <http://orcid.org/0000-0003-3109-716X>

Geliş Tarihi: 16.01.2023

Kabul Tarihi: 24.06.2023

### Öz

Mevcut enerji rezervlerinin azalması, fotovoltaik güneş enerjili sistemleri popüler hale getirmiştir. Sistemin etkin bir şekilde işletilebilmesi için etkin bir şekilde yönetilmesi ve ışınımının başarılı şekilde tahmin edilmesi gerekmektedir. Çalışma; Afyon Kocatepe Üniversitesi bünyesinde saatlik olarak ölçülmüş bir yıllık güneş ışınım verisi (1\*8760 boyutlu data seti) ve belirli saat aralıklarla (05:00 ile 14:00) ölçülen bir yıllık ışınım, basınç ve ortalama sıcaklık değerlerini içeren 3\*7310 boyutlu data seti kullanılarak, Yapay Sinir Ağları temelli birden fazla modellerle gerçekleştirilmiştir. Birinci model; 1\*8760 veri boyutuna sahip bir yıllık ışınım verisiyle, ikinci ve üçüncü model ise; günlük 10'ar saatlik kayıtlar altına alınan farklı girdi değerlerinin kullanılmasıyla oluşturulmuştur. Aynı tarihlerde aynı bölge için alınan farklı ölçüm değerleri ile yapay sinir ağları eğitilmiş ve performansları kıyaslanmıştır. Gerçekleştirilen çalışmada birinci modelin başarı oranı %87,78, ikinci modelde başarı oranı %73, üçüncü modelde ise %71'dir. Çalışma; girdi verilerinin, gizli katmanda kullanılacak nöron sayısının ve kullanılacak eğitim fonksiyonunun önemine dikkat çekilmiştir.

### Anahtar kelimeler

Işınım; Güneş; Tahmin;  
Yapay Sinir Ağları  
(YSA); Modelleme.

## Effects of Artificial Different Neural Network Methods on Experimentally Measured Solar Radiation Estimation

### Abstract

The decrease in available energy reserves has made photovoltaic solar systems popular. In order for the system to be operated effectively, it must be managed effectively and its radiations must be predicted successfully. The study; A yearly solar radiation data (1\*8760 size data set) measured hourly within Afyon Kocatepe University and a 3\*7310 size data containing the annual radiation, pressure and average temperature values measured at certain hourly intervals (05:00 am - 02:00 pm). It has been carried out with multiple models based on Artificial Neural Networks, using the set. First model; With a one-year radiation data with a data size of 1\*8760, the second and third models; It was created by using different input values recorded daily for 10 hours. Artificial neural networks were trained with different measurement values taken for the same region on the same dates and their performances were compared. In the study carried out, the success rate of the first model was 87.78%, the success rate of the second model was 73%, and the third model was 71%. Study; The importance of the input data, the number of neurons to be used in the hidden layer and the training function to be used has been pointed out.

### Keywords

Radiation; Sun;  
Prediction; Artificial  
Neural Networks  
(ANN); Modelling.

### 1. Giriş

Küresel ısınmanın artması, mevcut fosil enerji kaynak rezervlerinin azalması, yenilenebilir enerjiye yönelmeyi zorunlu hale getirmiştir. Özellikle ülkemizdeki mevcut enerjinin, rezervi sıkıntılı olan

petrol ve doğalgaz gibi yakıtlardan karşılandığı göz önüne alındığında yenilenebilir enerji türlerine yapılacak olan yatırımların daha da artacağına işaretler (Jain *et al* 2011).

Yenilenebilir enerji arasında güneş enerjisinden elektrik enerjisine dönüşüm için tasarlanan

sistemler, verimlilikleri düşük olsa bile amortisman süresi ve kullanım kolaylığı bakımından diğer sistemler ile karşılaştırıldığında avantaj sağlamaktadır. Ülkemiz, güneş kuşağı olarak adlandırılan bölgede bulunması ve güneş enerjisi açısından zengin bir konumda yer almasıyla, fotovoltaik güneş panellerinin kullanımına son derece elverişlidir. Güneş enerji sistemlerinin kullanımının artışıyla birlikte, günümüz enerji problemi, çevreye zarar vermeden çözüme yaklaşacaktır (Angarita and Usaola, 2007).

Güneş panellerinin doğru ve etkin kullanılabilmesi önemli bir konudur. Güneş ışınlarının sağladığı enerji her bölgede aynı değildir. Panellerden elde edilen enerjinin artırılabilmesi gelen ışınım ile orantılı bir durumdur (Bakırcı, 2009). Yenilenebilir Enerji Genel Müdürlüğü'nün yaptığı açıklamalara göre ülkemizin günlük güneş ışığı (güneşlenme) süresi 7,2 saat civarındadır. Yeryüzüne ulaşan güneş enerji potansiyellerinin tespit edilebilmesi fotovoltaik (FV) sistemlerin verimliliği bakımından oldukça önemli bir konudur (Güçlü, 2020). Bir bölgenin enerji potansiyelini tespit edebilmek için; gözlem cihazlarına, verilerin kaydedilebilmesi için gerekli kayıt cihazlarına, gözlem istasyonlarına vb. gibi birçok ekipmanlara ihtiyaç duyulmaktadır. Ekipman maliyetleri ve işlemlerin zorlukları güneş ışınım tahminlemenin önemini ortaya çıkarmaktadır (H. Glahn and D. Lowry, 1972).

Tahminlemenin amacı, gelecek hakkında bir fikir oluşumunu sağlamaktır. Belirsizliklerin önüne geçerek, geleceğe yönelik yatırımların sağlıklı olmasına yardımcı olmaktır. Ancak tahminleme modellerinin yanlış oluşturulması istenilen bir durum değildir (Köken, 2022). Tahminleme modelleri doğru oluşturulmuş yöntemlerin dahi dezavantajları olabilmektedir. Yöntem her ne kadar doğru modelleme yapsa da gözlem dışı bir değer üretmesi tahminlemenin bir dezavantajıdır ve hata payının olması beklenen bir durumdur (Makridakis and Wheelwright, 1989). Tahmin yöntemleri, geçmiş verileri işleyerek veya öğrenerek gelecekte benzer koşullar altında meydana gelebilecek durumlar hakkında başarılı sonuçlar elde etmektedir (Prasad *et al* 2016).

Tahmin sonuçlarında hatanın en az seviyelerde olması istenir. Öncelikle mevcut veriler için yapay sinir ağları (YSA) eğitilir. Eğitim sonucunda ve test sonucunda YSA'nın yaptığı tahmin verilerine bakılır. YSA'nın başarı oranı yüksek ise, yani YSA'da gerçekleştirilen yöntem başarılı kabul edilebilir ise gelecek değerlere yönelik tahminleme ile devam edilir. Ancak yetersiz ise yeni bir modelin tanımlanarak işlemlerin tekrarlanması gerekmektedir.

Yenilenebilir enerji sistemlerin kullanım alanlarının yaygınlaşması ve genişlemesi nedeniyle, güneş radyasyonu ile ilgili daha doğru modelleme ve tahmin yöntemlerine ihtiyaç artmaktadır. Dünya yüzeyine ulaşan güneş ışınımı birçok çevresel etkilere bağlı olduğu için tahminleme güçleşmektedir. Tahmin değerleri FV uygulamalarının tasarımında gereklidir. Sabit sıcaklıktaki güneş panelinde, güç üretimi küresel radyasyona doğrudan bağlıdır ve güneş radyasyonunu tahmin etmek FV gücünü tahmin etmekten neredeyse farksızdır (J. Cao and S. Cao, 2005).

Tahminleme yöntemleri tahmin süresi ve girdi tipine göre farklılık göstermektedir. Literatürde bu konuda gerçekleştirilen birçok yöntem ve araştırma mevcuttur (Şekertekin, 2019). Bu çalışma, YSA ile birden fazla ağ kurularak gerçekleştirilmiş olup, ışınımın tahmin edilirken farklı girdi verilerinin kullanılmasıyla oluşturulan modellerin performansları birbirleri ile karşılaştırılmıştır (Kara, 2019).

Gerçekleştirilen çalışmada oluşturulan Yapay Sinir Ağları modellerinin tahminleme üzerine etkisi araştırılmıştır. Kullanılan birinci modelde kesintisiz bir şekilde kayıt altına alınan 24 saatlik ışınım verisi ile oluşturulmuş ışınım verisi kullanılmıştır. İkinci ve üçüncü modelde ise belirli saatlerde kayıt altına alınan ışınım, basınç ve ortalama sıcaklık değerini içeren veri setleri kullanılmıştır. Bu modellerin karşılaştırılmasındaki amaç girdi verilerinin türlerinin ve boyutunun Yapay Sinir Ağları modelleri üzerine etkilerinin araştırılmasıdır. Oluşturulan Yapay Sinir Ağları modelleri farklı eğitim

fonksiyonları ve farklı nöron sayılarıyla eğitilerek, oluşturulan modellerde eğitim fonksiyonlarının ve gizli katman nöron sayılarının etkisi gözlemlenmiştir. Modellerin oluşturulması, verilerin kullanılması ve elde edilen başarı oranlarına makalenin diğer bölümlerinde daha ayrıntılı yer verilmiştir.

Kullanılan yöntemler sayesinde oluşturulan modeller için en uygun eğitim fonksiyonu ve en doğru gizli katman nöron sayısı seçilebilecektir. Ayrıca girdi verileri içerisinde başarı oranına az etkileyen data setlerinin ayıklanması oluşturulan modelin daha hızlı çalışmasını sağlayacaktır. Kullanılan modelin dezavantajı ise eğitim fonksiyonlarının ve nöron sayılarının birden fazla denemesi modelin çalışma süresini artırmaktadır.

## 2. Materyal ve Metot

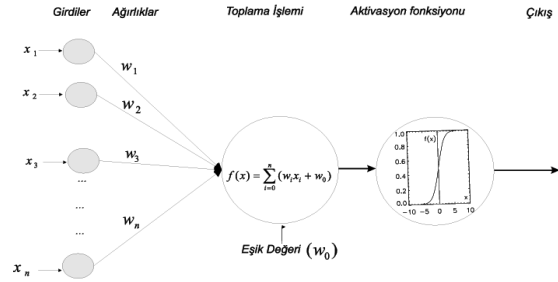
Yapay zekâ yöntemlerinden biri olan yapay sinir ağları son zamanların popüler konusu haline gelmiştir. Sunduğu imkanlar ve kullanımının kolay olması sebebiyle birçok alanda sıklıkla tercih edilmektedir. Bu çalışmada, doğrusal olmayan ve karmaşık güneş ışınım verileri, yapay sinir ağları yardımıyla tahmin edilmektedir (Akarslan ve Hocaoglu, 2018). Kullanılan değerler aynı tarihler için farklı yöntemler ile kaydedilmiş, Afyonkarahisar şehrine ait bir yıllık ışınım verileridir. Işınım verileri bulutluluk, nem gibi veya birçok öngörülemez sebeplerden dolayı atmosfer dışı ışınımına göre bozulabilir. Düzgün bir doğrusallık göstermemesi sebebiyle güneş ışınım verilerinin tahmini normal şartlarda mümkün olamayacak kadar zordur. Ancak yapay sinir ağlarının ve benzer birçok yöntemlerin geliştirilmesi ile tahminlemeleri gerçekleştirmek kolaylaşmaktadır (Louzazni M et al, 2022).

YSA, insan beyninin çalışma ilkesinden esinlenilerek oluşturulmuş bir sistemdir. İnsan beynindeki sinir hücrelerinin yapay olarak taklit edilmesini baz alarak oluşturulmuştur ve karmaşık problemleri çözmek amacıyla bilgisayar sistemlerine uygulanmaktadır (Ceylan ve Bulkan, 2018). Mükemmel bir veri işleme tekniği olarak kabul edilebilir. YSA kendisine verilen örnek verileri kullanarak öğrenmektedir. Çok karmaşık ve doğrusal olmayan verilerin

çözülmesinde büyük kolaylıklar sağlamaktadır (Arslan, G. vd 2019).

YSA'nın yapay sinir hücrelerinden bir diğer adıyla nöronlardan meydana gelmektedir. YSA'nın girişindeki verilere; girdiler denir. Girişindeki girdiler YSA'nın kendi belirlediği ağırlıklar ile çarpımıyla çıktı değerleri oluşmaktadır. Bu işlemler aktivasyon fonksiyonu ile gerçekleştirilir. Sonucu oluşturmak için aktivasyon fonksiyonunun etkisi yüksektir. Çıktılar; aktivasyon fonksiyonuna göre işlem yapılarak alınır. Bir yapay sinir hücresinin öğrenme yeteneği, seçilen öğrenme algoritması içerisinde ağırlıkların uygun bir şekilde ayarlanmasına bağlıdır. Şekil 1'de YSA'nın matematiksel olarak genel yapısı gösterilmektedir. Şekilde aktivasyon fonksiyonu kısmında, bu çalışmada da kullanılan, sigmoid fonksiyonu görülmektedir (Şahan ve Okur 2016).

Her bir tabakayı birbirlerine bağlayan ileri yayımlı (Feedforward Propagation) ya da geriye yayımlı (Feedback propagation) olmak üzere iki tane öğrenme (training) algoritması vardır.




Şekil 1. YSA'nın Matematiksel Olarak Genel Yapısı

En iyi öğrenme algoritmalarının başında Levenberg-Marquardt öğrenme algoritması kullanan geri yayımlı YSA olduğu görülmektedir (Yıldız vd. 2023).

### 2.1 Modellerin Oluşturulması

Bu çalışmada yapay sinir ağları farklı yöntemlerle kurulmuştur. Tasarlanan ilk yapay sinir ağı 1\*8760 veri boyutuna sahip bir yıllık (01 Ocak 2011 – 31 Aralık 2011) ışınım verisi ile kurulmuştur. Kullanılan bir yıllık ışınım verisi şekil 2'de gösterildiği gibidir. Yapay sinir ağının tahmin yapabilmesi için veri seti girdi matrisi ve çıktı vektör olarak düzenlenmiştir. Girdi matrisi ve çıktı vektörü; YSA her 24 saatlik eğitimin sonunda bir sonraki ışınım değerini tahmin edebilecek şekilde ayarlanmıştır. Girdi matrisi

8736\*24 boyutunda bir matris ve çıktı vektörü de 8736\*1 şeklinde oluşmuştur.




Şekil 2. Bir Yıllık (8760 Saatlik) Işınım Verisi

İkinci yöntemde, çıkışta belirli saatler için (05:00 – 14:00) tahmin edilmesi istenen ışınım değeri için; girişte belirli saatlerde alınan (05:00 – 14:00) ışınım, basınç ve sıcaklık değerleri kullanılmıştır. Üçüncü modelde ise ışınım verilerinin tahmininde, özellik seçiminin önemine dikkat edilebilmesi amacıyla giriş olarak sadece sıcaklık ve basınç verileri, çıkış ise ışınım verisi olarak tasarlanmıştır. Oluşturulan 3 modelin performansları birbirleri ile mukayese edilmiştir. Başarı oranı R kare yüzde başarı olarak verilmiştir. Oluşturulan modelde verilerin %80'i eğitim için %20'si ise test olarak kullanılmıştır.

İlk olarak çıktı verileri olan ışınım miktarları aynı zamanda girdi vektörü olarak da kullanılmış ve YSA eğitilmiştir. Elde edilen sonuçlar kaydedilerek YSA'nın başarı sonuçları değerlendirilmiştir. Oluşturulan modeller, farklı nöron sayıları ve farklı eğitim fonksiyonları ile eğitilerek test edilmiştir (Ehmeind Maham and Akarslan, 2022).

Gerçekleştirilen modellerde bir adet gizli katman kullanılmıştır. Aktivasyon fonksiyonu olarak en yaygın kullanılan aktivasyon fonksiyonu sigmoid fonksiyon seçilmiştir (Momeni el all, 2014). Birden fazla eğitim fonksiyonu ile ayrı ayrı eğitilen modeller tasarlanırken gizli katman nöron sayısı da algoritmalar yardımıyla farklı değerlerde denenmiştir ve başarı oranı en yüksek ağ modeli tespit edilmiştir. Oluşturulan yapay sinir ağları modeli Şekil 3'te gösterildiği gibidir.



Şekil 3. Kullanılan YSA Modelinin Yapısı

Oluşturulan modeller, 8 adet eğitim fonksiyonu ile ayrı ayrı eğitilmiştir. Kullanılan eğitim fonksiyonları sırasıyla; TrainLMLevenberg-Marquardt (TrainLM), Conjugate gradient with Polak-Ribière (TrainCGP), Gradient descent with momentum and adaptive learning rate (TrainGDX), Scaled conjugate gradient (TrainSCG), Resilient (TrainRP), One-step secant (TrainOSS), Conjugate gradient with Fletcher - Reeves Updates (TrainCGF)TrainCGF, BFGS quasi-Newton (TrainBFG) eğitim fonksiyonlarıdır. Çalışmanın bundan sonraki bölümlerinde eğitim fonksiyonları kısaltmalarıyla belirtilecektir. Gerçekleştirilen modellerin doğruluk oranları performans değerlendirme kriterleri olan Ortalama Kare Hatası (Mean Squared Error – MSE), Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hata (RMSE) ile kontrol edilmiştir (Gökçe ve Sonugür, 2015). Değerlendirme performanslarına ait denklemler aşağıda verildiği gibidir.

Ortalama Kare Hatası (Mean Squared Error – MSE);

$$MSE = \frac{1}{n} \sum_{k=1}^n e^2 \quad (1)$$

Kök Ortalama Kare Hata (RMSE);

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n e^2} \quad (2)$$

Ortalama Mutlak Hata (MAE);

$$MAE = \frac{1}{n} \sum_{k=1}^n |e| \quad (2)$$

Gerçekleştirilen modelde test sonuçlarına göre performansı en iyi olan ağ, 'trainlm' (Levenberg-Marquardt) ve 'traincgf' (Fletcher-Powell Conjugate Gradient) eğitim fonksiyonu ile eğitilen ağ olmuştur. Oluşturulan YSA modeline ait hata katsayıları çizelge 1'de verildiği gibidir. Çizelge test sonuçlarına göre sıralanmış olup, başarı oranı en yüksekte en düşüğe doğru sıralanmıştır. Nöron sayılarının etkisi çalışmanın ilerleyen bölümlerinde açıklanmıştır (Yıldız vd. 2023).

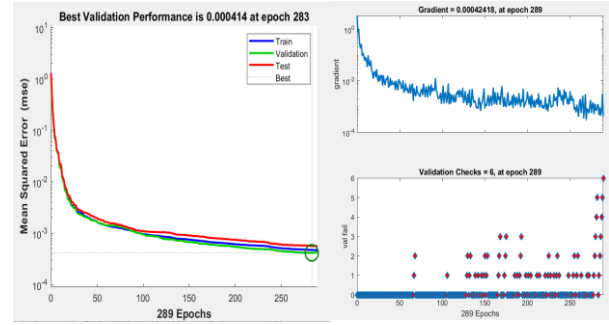
Eğitim performansları karşılaştırıldığında Yapay Sinir Ağ modeli en iyi performansı TrainCGF ,TrainRP ve TrainLM eğitim fonksiyonları ile eğitildiğinde elde edilmiştir. Ancak TrainCGP eğitim fonksiyonu ile eğitilen ağın eğitim performansı diğer ağlara göre düşük gibi gözükürken, test performansının yüksek olduğu görülmüştür. Birinci modele ait en iyi test performansı TrainLM eğitim fonksiyonu kullanılarak eğitilen 15 nöronlu ağa aittir ve modele ait performans grafikleri Şekil 4’te gösterilmiştir.

Oluşturulan Yapay Sinir Ağ modellerinin başarıları farklı grafiklerle gösterilmiştir. MSE-Epochs grafiği, YSA'nın eğitim örneklerine karşı ortalama karesel hata (Mean Squared Error - MSE) değerlerinin, eğitim süreci boyunca nasıl değiştiğini göstermektedir. Bu grafik, YSA modelinin başarı oranının belirlenmesinde önemli bir gösterge olarak kullanılır. MSE değeri ne kadar düşük olursa, modelin performansı o kadar yüksek olur.

Gradient - Epoch grafiği YSA'nın eğitim sırasında gradient değerlerinin değişimini göstermektedir. Gradient, ağın eğitim verilerine uyum sağlamasını

sağlamak için kullanılan bir optimizasyon algoritmasıdır. Bu grafikteki değerler, gradient değerinin ne kadar doğru bir şekilde hesaplandığını gösterir.

Validation Checks – Epoch grafiği ise YSA'nın eğitim sırasında doğrulama setindeki başarısını göstermektedir. Bu grafik, modelin doğrulama verileri üzerindeki performansını izlemek için kullanılır. Doğrulama seti, modelin genelleştirilmesini ve aşırı uyuma (overfitting) karşı korunmasını sağlar.




Şekil 4. Birinci YSA Modeline Ait Performans Grafikleri (TrainLM ile Eğitilen 15 Nöronlu Ağ)

Çizelge 1. Oluşturulan Birinci Modele Ait YSA için Hata Katsayıları

Eğitim Fonksiyonu	Nöron Sayısı	Eğitim			Test				
		MAE	MSE	RMSE	Başarı Oranı (%)	MAE	MSE	RMSE	Başarı Oranı (%)
Levenberg-Marquardt (TrainLM)	15	0,1213	0,0421	0,2052	87,8670	0,1221	0,0435	0,2085	87,7853
Conjugate gradient with Fletcher-Reeves Updates (TrainCGF)	14	0,1214	0,0422	0,2054	87,8572	0,1223	0,0437	0,2089	87,7666
Resilient (TrainRP)	14	0,1218	0,0426	0,2064	87,8180	0,1223	0,0437	0,2089	87,7661
Conjugate gradient with Polak-Ribière (TrainCGP)	15	0,1216	0,0424	0,2060	87,8357	0,1224	0,0438	0,2092	87,7553
BFGS quasi-Newton (TrainBFG)	15	0,1214	0,0422	0,2054	87,8572	0,1225	0,0438	0,2092	87,7545
One-step secant (TrainOSS)	20	0,1216	0,0424	0,2059	87,8397	0,1225	0,0438	0,2093	87,7516
Conjugate gradient with Polak-Ribière (TrainCGP)	17	0,1216	0,0424	0,2059	87,8395	0,1225	0,0438	0,2093	87,7500
Scaled conjugate gradient (TrainSCG)	15	0,1216	0,0424	0,2059	87,8430	0,1227	0,0440	0,2097	87,7318
Gradient descent with momentum and adaptive learning rate (TrainGDX)	17	0,1222	0,0428	0,2068	86,7952	0,1236	0,0458	0,2139	86,6925

Levenberg-Marquardt (TrainLM)	18	0,1206	0,0413	0,2033	87,9430	0,1235	0,0448	0,2117	87,6515
Levenberg-Marquardt (TrainLM)	19	0,1206	0,0414	0,2034	87,9426	0,1229	0,0442	0,2103	87,7095
Conjugate gradient with Fletcher - Reeves Updates (TrainCGF)	24	0,1211	0,0419	0,2047	87,8876	0,1227	0,0440	0,2099	87,7276
Resilient (TrainRP)	22	0,1211	0,0419	0,2047	87,8871	0,1228	0,0441	0,2100	87,7209

Birinci modelin başarı grafiği ise Şekil 5'te gösterilmiştir. Grafikteki doğrular, veri yoğunluğunun çok olduğu bölgelere işaret etmekte, uyumsuz veriler ise hata olarak kabul edilmektedir. Oluşturulan ikinci modelde ise aynı tarihler arasında, belirli saatlerde ölçülen ışınım, sıcaklık ve basınç değerleri kullanılarak gerçekleştirilmiştir.



Şekil 5. Birinci YSA Modeline Ait Başarı Grafiği (TrainLM ile Eğitilen 15 Nöronlu Ağ)

Giriş verileri olarak ışınım, saat, ortalama sıcaklık ve basınç değerleri kullanılmıştır. Girdi matrisi 7310\*13 boyutundadır. Karşılığında ise 7310\*1 boyutunda ışınım verilerinden meydana gelen çıktı vektörü kullanılmıştır.

Gerçekleştirilen ikinci modele ait hata katsayıları Çizelge 2'de gösterilmiştir. Çizelge test sonuçlarına göre başarı oranı en yüksekten en az olana göre dizilmiştir.

Eğitim performansları karşılaştırıldığında, Yapay Sinir Ağ modeli en iyi performansını TrainLM eğitim fonksiyonu ile eğitilen ağ modelinde gerçekleştirmektedir. Ancak test verileri için ise en başarılı ağ TrainRP eğitim fonksiyonu ile eğitilen modelde ortaya çıkmaktadır.

Çizelge 2. Oluşturulan İkinci Modele Ait YSA için Hata Katsayıları

Eğitim Fonksiyonu	Nöron Sayısı	Eğitim İçin				Test İçin			
		MAE	MSE	RMSE	Başarı Oranı (%)	MAE	MSE	RMSE	Başarı Oranı (%)
TrainRP	22	0,2658	0,0977	0,3126	73,4225	0,2702	0,0985	0,3138	72,9791
TrainBFG	16	0,2661	0,0981	0,3132	73,3869	0,2709	0,0991	0,3148	72,9122
TrainLM	20	0,2645	0,0965	0,3106	73,5493	0,2711	0,0994	0,3152	72,8876
TrainLM	18	0,2657	0,0977	0,3125	73,4267	0,2712	0,0994	0,3153	72,8811
TrainBFG	24	0,2662	0,0981	0,3133	73,3802	0,2714	0,0996	0,3156	72,8630

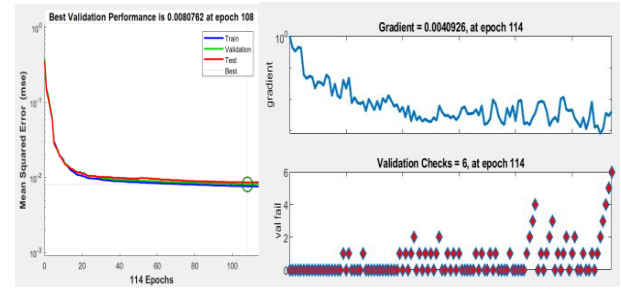
TrainLM	25	0,2651	0,0970	0,3115	73,4928	0,2714	0,0997	0,3157	72,8568
TrainCGF	25	0,2656	0,0975	0,3123	73,4416	0,2716	0,0999	0,3160	72,8384
TrainCGP	12	0,2668	0,0987	0,3142	73,3223	0,2717	0,0999	0,3161	72,8331
TrainSCG	26	0,2654	0,0974	0,3120	73,4580	0,2718	0,1000	0,3163	72,8221
TrainOSS	24	0,2675	0,0994	0,3153	73,2538	0,2720	0,1002	0,3165	72,8048
TrainCGP	16	0,2657	0,0976	0,3124	73,4328	0,2722	0,1005	0,3170	72,7758
TrainCGF	29	0,2649	0,0968	0,3112	73,5133	0,2723	0,1006	0,3172	72,7660
TrainLM	23	0,2656	0,0976	0,3124	73,4378	0,2724	0,1006	0,3172	72,7632
TrainGDX	10	0,2684	0,1004	0,3168	73,1585	0,2759	0,1041	0,3227	72,4102

Bunların dışında başarısız olan ağlarda mevcuttur. Başarı oranı en kötü 4 yapay sinir ağ modeli Çizelge 3'te verilmiştir.

Oluşturulan model için başarısız en kötü ağlar TrainGDX eğitim fonksiyonu ile eğitilen ağlarda ortaya çıkmaktadır. Eğitim fonksiyonunun aynı olmasına rağmen farklı başarı oranlarının görülmesi modelde kullanılan nöron sayıları ile alakalıdır. TrainGDX eğitim fonksiyonu ile eğitilen ağ için nöron sayısının 10 olması durumunda başarı oranı %73'ün üzerindeyken, nöron sayısının 28 olması durumunda başarı oranı %46 seviyelerine gerilemektedir. Nöron sayılarının başarı oranına olan etkisi iki çizelgede de net bir şekilde görülmektedir.

Değerler incelendiğinde nöron sayıları ile başarı oranının doğru orantılı olmadığı görülmektedir.

Oluşturulan ikinci modele ait en iyi test performansı TrainRP eğitim fonksiyonu kullanılarak eğitilen 22 nöronlu ağa aittir ve modele ait performans grafikleri Şekil 6'da gösterildiği gibidir.



Şekil 6. İkinci YSA Modeline Ait Performans Grafikleri (TrainRP ile Eğitilen 22 Nöronlu )

Çizelge 3. Oluşturulan İkinci Modele Ait En Kötü Durumlar

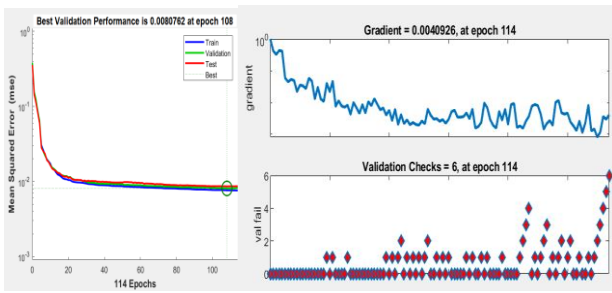
Eğitim Fonksiyonu	Nöron Sayısı	Eğitim				Test			
		MAE	MSE	RMSE	Başarı Oranı (%)	MAE	MSE	RMSE	Başarı Oranı (%)
TrainGDX	28	0,5336	0,3867	0,6218	46,6413	0,5367	0,3891	0,6238	46,3344
TrainGDX	29	0,4962	0,3706	0,6087	50,3812	0,5033	0,3718	0,6098	49,6694
TrainGDX	26	0,4161	0,2694	0,5190	58,3886	0,4242	0,2750	0,5244	57,5839
TrainGDX	30	0,4079	0,2696	0,5193	59,2072	0,4161	0,2740	0,5235	58,3850

Oluşturulan model için başarısız en kötü ağlar TrainGDX eğitim fonksiyonu ile eğitilen ağlarda

ortaya çıkmaktadır. Eğitim fonksiyonunun aynı olmasına rağmen farklı başarı oranlarının görülmesi

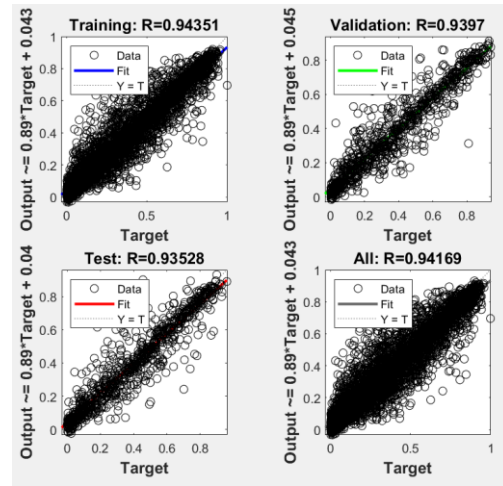


modelde kullanılan nöron sayıları ile alakalıdır. TrainGDX eğitim fonksiyonu ile eğitilen ağ için nöron sayısının 10 olması durumunda başarı oranı %73'ün üzerindeyken, nöron sayısının 28 olması durumunda başarı oranı %46 seviyelerine gerilemektedir. Nöron sayılarının başarı oranına olan etkisi iki çizelgede de net bir şekilde görülmektedir. Değerler incelendiğinde nöron sayıları ile başarı oranının doğru orantılı olmadığı görülmektedir. Oluşturulan ikinci modele ait en iyi eğitim performansı ise TrainLM eğitim fonksiyonu kullanılarak eğitilen 25 nöronlu ağa aittir ve modele ait performans grafikleri Şekil 7'de gösterildiği gibidir.



Şekil 7. İkinci YSA Modeline Ait Performans Grafikleri (TrainLM ile Eğitilen 25 Nöronlu Ağ)

İkinci modelin başarı grafiği ise Şekil 8'de gösterilmiştir. Oluşturulan diğer modelde ise yine aynı tarihler arasında, belirli saatlerde ölçülen ışınım, sıcaklık ve basınç değerleri kullanılarak gerçekleştirilmiştir.



Şekil 8. İkinci YSA Modeline Ait Başarı Grafiği (TrainRP ile Eğitilen 22 Nöronlu Ağ)

Ancak bu modelde giriş verisi olarak saat, sıcaklık ve basınç verileri kullanılmış, bu verilere dayanarak ışınım verisi tahmin edilmiştir. Oluşturulan YSA modeline ait hata katsayıları Çizelge 4'de verilmiştir. Oluşturulan üçüncü modelin ikinci model ile farkı girdi verilerinin değiştirilmesidir. İkinci modelde elde edilen ışınım verileri hem girdi hem çıktı matrisi olacak şekilde düzenlenirken üçüncü modelde kaydedilen ışınım verileri orijinal boyutuyla (7320\*1) sadece çıktı olarak kullanılmıştır. Buna karşın girdi matrisi saat bilgisi, basınç ve sıcaklık verilerinden meydana gelen bir matristen (7320\*3) oluşmaktadır (Agbo G *et al* 2012).


Çizelge 4. Oluşturulan Üçüncü Modele Ait YSA için Hata Katsayıları

Eğitim Fonksiyonu	Nöron Sayısı	Eğitim			Test				
		MAE	MSE	RMSE	Başarı Oranı (%)	MAE	MSE	RMSE	Başarı Oranı (%)
TrainLM	29	0,2856	0,1171	0,3422	71,4431	0,2881	0,1186	0,3444	71,1872
TrainRP	28	0,2883	0,1198	0,3462	71,1680	0,2883	0,1189	0,3448	71,1655
TrainBFG	22	0,2867	0,1182	0,3439	71,3275	0,2884	0,1189	0,3449	71,1574
TrainLM	11	0,2863	0,1178	0,3433	71,3686	0,2885	0,1190	0,3449	71,1550
TrainRP	26	0,2872	0,1187	0,3445	71,2812	0,2885	0,1191	0,3450	71,1452
TrainOSS	21	0,2875	0,1190	0,3449	71,2547	0,2890	0,1195	0,3457	71,0998
TrainCGF	14	0,2880	0,1195	0,3458	71,1969	0,2892	0,1197	0,3459	71,0846



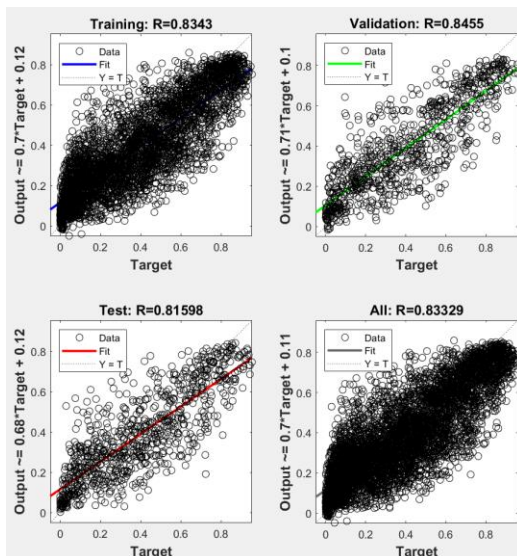
TrainBFG	23	0,2879	0,1194	0,3455	71,2146	0,2892	0,1197	0,3460	71,0760
TrainLM	11	0,2872	0,1187	0,3445	71,2820	0,2893	0,1198	0,3461	71,0746
TrainCGF	19	0,2875	0,1190	0,3450	71,2479	0,2894	0,1199	0,3462	71,0620
TrainSCG	15	0,2874	0,1189	0,3449	71,2577	0,2895	0,1200	0,3464	71,0498
TrainCGP	13	0,2879	0,1194	0,3456	71,2086	0,2896	0,1201	0,3465	71,0419
TrainCGP	17	0,2882	0,1197	0,3459	71,1841	0,2901	0,1206	0,3473	70,9925
TrainGDX	19	0,2883	0,1198	0,3461	71,1726	0,2901	0,1206	0,3473	70,9911

Oluşturulan üçüncü modele ait en iyi test performansı TrainLM eğitim fonksiyonu kullanılarak eğitilen 29 nöronlu ağa aittir ve modele ait performans grafikleri şekil 7'de gösterildiği gibidir.



Şekil 8. Üçüncü YSA Modeline Ait Performans Grafikleri (TrainLM ile Eğitilen 29 Nöronlu Ağ)

Girdi değişkenlerinin değiştirilmesi modelin başarı oranını etkilemektedir. Üçüncü modelin başarı grafiği ise Şekil 8'de gösterilmiştir.



Şekil 9. Üçüncü YSA Modeline Ait Başarı Grafiği (TrainLM ile Eğitilen 29 Nöronlu Ağ)

### 3. Sonuç ve Öneriler

Gerçekleştirilen üç modelde de aynı tarihe ait farklı zaman aralıklarıyla alınan ışınım verileri farklı yöntemlerle tahmin edilmeye çalışılmıştır. Modellerden elde edilen sonuçlar incelendiğinde yapay sinir ağları için eğitim fonksiyonunun ve nöron sayısının başarı oranına etkisi gözükmemektedir. Nöron sayılarının başarı oranı üzerinde etkili olduğu ancak başarı oranı ile doğru bir orantıya sahip olmadığı görülmektedir.

Işınım verileri birinci modeldeki gibi 24 saat boyunca kayıt altına alındığında oluşturulan modelin performansının daha yüksek olduğu görülmektedir. Ancak ikinci modeldeki gibi giriş verileri (ışınım, sıcaklık, basınç ve saat bilgileri) sadece belirli saatler aralığında alınırsa başarı oranının düştüğü anlaşılmaktadır. Üçüncü modelde ise giriş verilerinde ışınım verilerinin kullanılmaması başarı oranını daha da azaltmıştır.

Giriş verileri oluşturulurken tahminleme ile alakalı verilerin kullanılması ve verilerin tam olması başarı oranının yüksek olmasını sağlayacaktır. Bir tahminleme yapılırken girdi verilerinin, çıktı verilerini etkileyebilecek alakalı veriler olması gerekmektedir.

Birinci model için eğitim sırasındaki en yüksek başarı; Levenberg-Marquardt (TrainLM) eğitim

fonksiyonunun kullanılmasıyla elde edilmiştir. Eğitim sırasında 19 adet nöron kullanılmıştır. Test için ise yine Levenberg-Marquardt (TrainLM) eğitim fonksiyonu ile oluşturulan ve 15 adet gizli nöron kullanılan model daha başarılı olmuştur. Eğitim fonksiyonlarının ve nöron sayılarının oluşturulan modele uygun seçilmesi modelin başarı oranının artması için önemli bir konudur. Yapay sinir ağları modeli oluştururken girdilerin, tahmin edilmesi istenilen verilerle ilgisi ve boyutu da başarı oranı için önemli bir husustur.

## 5. Kaynaklar

- Agbo G. A., Ibeh G. F., Ekpe J. E., 2012. Estimation of global solar radiation at Onitsha with regression analysis and artificial neural network models. *Res. J. Recent Sci.*, 1 27-31.
- Akarşlan, E. and Hocaoğlu, F.O., 2018. Bir Fotovoltaik Güç Sisteminin Üretimine Çok Boyutlu Tahmin Filtreleri ile Modellenmesi. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 18(2), 516-522.
- Angarita J. and Usaola J., 2007. Combining hydro-generation and wind energy biddings and operation on spot electricity markets. *Electric Power Systems Research*, 77(5-6):393-400.
- Arşlan, G., Bayhan, B. and Yaman, K., 2019. Mersin / Türkiye için Ölçülen Global Güneş Işınımının Yapay Sinir Ağları ile Tahmin Edilmesi ve Yaygın Işınım Modelleri ile Karşılaştırılması. *Gazi University Journal of Science Part C: Design and Technology*, 7 (1) , 80-96.
- Bakırcı, K., 2009. Yatay Yüzeye Gelen Anlık Global Güneş Işınımının Tahmini İçin Basit Bir Hesaplama Metodu . *Isı Bilimi ve Tekniği Dergisi* , 29 (2) , 53-58 . Retrieved from <https://dergipark.org.tr/en/pub/isibttd/issue/33926/375558>
- Cao J. and Cao. S., 2005. Forecast of solar irradiance using recurrent neural networks combined with wavelet analysis. *Applied Thermal Engineering*, 25:161-172.
- Ceylan, Z. and Bulkan, S., 2018. Türkiye Ulaşım Kaynaklı Enerji İhtiyacının Hibrit ANFIS-PSO Metodu ile Tahmini *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 18 (2), 740-750.
- Ehmeind Maham, F. and Akarşlan, E. 2022. Güneş Işınım Tahmini için Farklı Güneşlenme Durumlarından Faydalanan Hibrit Bir Yöntem Tasarımı. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 22 (3), 588-596.
- Glahn H. and Lowry D., 1972. The use of Model Output Statistics (MOS) in objective weather forecasting, *Journal of Applied Meteorology*, 11:1203-1211.
- Gökçe, B. and Sonugür, G., 2015. ANFIS ve YSA Yöntemleri ile İşlenmiş Doğal Taş Üretim Sürecinde Verimlilik Analizi. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 16 (1), 174-185.
- Güçlü, Y. S. & Şen, Z., 2020. Güneş Işınımı Tahmini için Yeni Bir Yaklaşım: OrtLin Modeli . İklim Değişikliği ve Çevre, 5 (1) , 26-31 . Retrieved from <https://dergipark.org.tr/en/pub/idec/issue/53338/698839>
- Jain, A., Mehta, R. and Mittal, S.K., 2011. Modeling impact of solar radiation on site selection for solar PV power plants in India. *International Journal of Green Energy*, 8(4), 486-498.
- Kara A., 2019. Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini. *Gazi University Journal of Science Part C: Design and Technology* , 7 (4) , 882-892.
- Köken, E., 2022. Modeling the Throughput of Horizontal Shaft Impact Crushers Using Regression Analyses, Artificial Neural Networks and Multivariate Adaptive Regression Spline . *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi* , 22 (5) , 1193-1203 . DOI: 10.35414/akufemubid.1116702
- Louazani M., Mosalam H., and Khouya A., A non-linear auto-regressive exogenous method to forecast the photovoltaic power output, *Sustain. Energy Technol. Assessments*, vol. 38, p. 100670, Apr. 2020.
- Makridakis, S., and S. C. Wheelwright., 1989. Forecasting Methods for Management. 5th ed. New York: John Wiley & Sons, 102-170 pp.

Momeni, E.; Nazir, R.; Armaghani, D.J.; Maizir, H., 2014.

Prediction of pile bearing capacity using a hybrid genetic algorithm-based ANN. *Measurement*, 57: 122–131.

Prasad K., Gorai A.K., Goyal P., 2016. Development of

ANFIS models for air quality forecasting and input optimization for reducing the computational cost and time, *Atmos Environ.*, 128, 246–262.

Şahan M. and Okur Y., 2016. Akdeniz Bölgesine Ait

Meteorolojik Veriler Kullanılarak Yapay Sinir Ağları Yardımıyla Güneş Enerjisinin Tahmini. *Süleyman Demirel University Faculty of Arts and Science Journal of Science*, vol. 11, no. 1, pp. 61-71.

Şekertekin, A. 2019. Işınım Transferi Denklemi Baz

Alınarak Yer Yüzey Sıcaklığının Landsat-8 Uydu Verileri ile Haritalanması. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 19 (3) , 769-777 . DOI: 10.35414/akufemubid.559576

Yıldız E., Kelek M.M., Hocaoğlu F.O. and Oğuz Y., 2023.

Forecasting The Impact of Vaccination on Daily Cases in Turkey for Covid-19", *Academic Platform Journal of Engineering and Smart Systems*, vol. 11, no. 1, pp. 19-26.