



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 17.08.2022
Kabul Tarihi : 24.10.2022

Received Date : 17.08.2022
Accepted Date : 24.10.2022

METEOROLOJİK VERİLER KULLANILARAK GÜNEŞ IŞINIM TAHMİNİNDE YAPAY SİNİR AĞLARI PARAMETRELERİNİN DEĞERLENDİRİLMESİ

EVALUATION OF ARTIFICIAL NEURAL NETWORK PARAMETERS IN SOLAR RADIATION PREDICTION USING METEOROLOGICAL DATA

Erşan Ömer YÜZER¹ (ORCID: 0000-0002-9089-1358)
Altuğ BOZKURT^{2*} (ORCID: 0000-0001-6458-1260)

¹Hakkari Üniversitesi, Çölemerik Meslek Yüksekokulu, Elektrik Bölümü, Hakkari, Türkiye
²Yıldız Teknik Üniversitesi, Elektrik Mühendisliği Bölümü, İstanbul, Türkiye

*Sorumlu Yazar / Corresponding Author: Altuğ BOZKURT, abozkurt@yildiz.edu.tr

ÖZET

Doğru ışınım tahmini, fotovoltaik (PV) santralının verimliliğini arttırarak şebekenin etkin bir şekilde programlanmasına ve güç kalitesinin iyileştirilmesine olanak sağlar. Bu çalışma, güneş enerjisi bakımından verimli bir yer olan Hakkâri ilinde kurulan bir meteoroloji ölçüm istasyonu verileri aracılığıyla küresel güneş ışınım tahmininde yapay sinir ağları (YSA) parametrelerinin potansiyelini göstermektedir. Meteoroloji istasyonundan zaman serisine bağlı olarak ölçülen, rüzgâr hızı, sıcaklık, basınç ve nem parametreleri kullanılarak eş zamanlı gerçekleşen güneş ışınım değerleri YSA modeli oluşturularak tahmin edilmiştir. Oluşturulan model YSA’da yaygın olarak kullanılan çeşitli eğitim algoritmaları ve aktivasyon fonksiyonları ile denenmiş ve en iyi sonuç elde edilmeye çalışılmıştır. Kullanılan modelin performansı istatistiksel göstergeler kullanılarak değerlendirilmiştir. Kullanılan veri seti parametrelerine göre güneş ışınım tahmininde, “*trainlm*” eğitim algoritması ile “*poslin*” aktivasyon fonksiyonu kullanılarak oluşturulan model 0,97 regresyon değeri, %1,16 ortalama kare hatası (MSE) ve %0,0881 normalize kök ortalama kare hatası (nRMSE) değeri ile güneş ışınım tahmininde en iyi performansı göstermiştir.

Anahtar Kelimeler: Güneş ışınım tahmini, güneş enerjisi, Hakkâri, yapay sinir ağları, meteorolojik veriler

ABSTRACT

Accurate radiation prediction increases photovoltaic (PV) plant efficiency so ensures effective programming of the grid and improvement of power quality. This study demonstrates the prediction potential of artificial neural networks (ANN) parameters in global solar radiation through data from a meteorological measurement station established in Hakkari, Turkey, which is a solar-efficient place. The occurring simultaneous solar radiation values were estimated using the wind speed, temperature, pressure and humidity parameters obtained from the meteorology station depending on the time series, and the relationships between these parameters were modeled using ANN. The created model was tested with various training algorithms and activation functions, and the best result was tried to be obtained. The performance of this model was evaluated using statistical indicators. In prediction of solar radiation according to used data set parameters, the model established by using “*trainlm*” training algorithm and “*poslin*” activation function showed the best performance in solar radiation prediction with 0.97 regression value, 1.16% mean square error (MSE) and 0.0881% normalized root mean square error (nRMSE).

Keywords: Solar radiation prediction, solar energy, Hakkari, artificial neural networks, meteorological data

ToCite: YÜZER, E.Ö., & BOZKURT, A., (2022). METEOROLOJİK VERİLER KULLANILARAK GÜNEŞ IŞINIM TAHMİNİNDE YAPAY SİNİR AĞLARI PARAMETRELERİNİN DEĞERLENDİRİLMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*,25(4), 746-759.

GİRİŞ

Güneş ve rüzgâr gibi yenilenebilir enerji kaynakları, fosil yakıtların kullanımını azaltmada, buna bağlı olarak karbondioksit emisyonlarını düşürmede ve küresel ısınmayı etkili bir şekilde azaltmada çok önemli bir rol oynamaktadır (Zeng vd. 2020; Molina vd. 2017). Bütün dünya ülkeleri iklim değişikliğine neden olan enerji kaynaklarının kullanımı ile ilgili etkili kararlar almaktadır. Bu nedenle yenilenebilir enerji kaynaklarını enerji sistemlerine entegre etme isteği çok popüler hale gelmiş ve PV sistemler hızla gelişerek önemli bir yenilenebilir enerji sistemi haline gelmektedir. Dünyada, güneş PV küresel kurulu güç kapasitesi 2020 yılında 710 GW değerine yaklaşmıştır. En yüksek kurulu güneş PV kapasitesine sahip bazı ülkeler Tablo 1’de gösterilmiştir (IRENA, Renewable Energy Statistics, 2021).

Tablo 1. En Yüksek Güneş Enerjisi Kurulu Kapasitesine Sahip Ülkeler (MW)

Çin	253.834	Güney Afrika	5.490	Türkiye	6.667	Almanya	53.781	ABD	73.814
Japonya	68.665	Mısır	1.659	Rusya	1.428	İtalya	21.594	Brezilya	7.879
Hindistan	38.983	Cezayir	423	Ermenistan	0.95	Birleşik Krallık	13.462	Meksika	5.630

Güneş enerjisi sistemlerinde enerji üretimi, farklı atmosferik değişkenlere bağlı olarak güneş ışınımının doğru bir şekilde belirlenmesini ve tahminini içerir. Güneş ışınımı, güneş enerjisinin korunması, mimari tasarım, tarımsal üretim ve yüzey atmosfer etkileşimi gibi birçok uygulama için gerekli olan birincil yenilenebilir enerji kaynağıdır (Lu vd., 2011). Ancak, güneş ışınımını yeryüzünden ölçen sensörlerin maliyetinin yüksek olması ve sürekli bakım ve kalibrasyon gerektirmesi nedeniyle güneş ışınımı ölçümlerinin her noktada ölçülmesi mümkün değildir (Othman vd., 2020). Işınım değerlerinin sınırlı kapsamı, daha kolay elde edilebilen diğer verilere dayalı olarak güneş ışınımını tahmin etmek için modeller geliştirmeye ihtiyacı belirler.

Literatür Özeti

Güneş ışınımının doğru tahmini, elektrik şebekesinin güvenliğini sağlamak ve alternatif enerji kaynaklarının mevcut rezervlerini makul bir şekilde depolamak için önemli bir rol oynar (Huang vd., 2017). Son yıllarda, araştırmacılar birçok güneş ışınım tahmin yöntemi sunmuştur. Bu yöntemler temel olarak fiziksel, istatistiksel ve hibrit olmak üzere 3 kategoriye ayrılabilir.

Fiziksel yöntemler, matematiksel denklemlere dayanır ve çözümler sayısal yöntemlerle elde edildiği için, sayısal hava tahminlerini (NWP), gökyüzü görüntüleyicileri ve uydu görüntüleme modellerini içerir (Cornaro vd., 2015). Birçok çalışmada; sıcaklık, nem, yağış olasılığı, rüzgâr gibi değişkenleri önceden belirlemek ve yüzey güneş ışınımını tahmin etmek için fiziksel yöntemler kullanılmıştır (Tuohy vd., 2015). Joshi ve arkadaşları, Avustralya bölgesinde, Lima ve arkadaşları ise Brezilya Kuzey-doğu bölgesi için Hava Durumu Araştırma ve Tahmin Modelini (WRF) istatistiksel bir son işleme yöntemiyle birleştirerek 24 saatlik güneş ışınımı tahminleri üretmek için bir metodoloji oluşturmuşlardır (Joshi vd., 2019; Lima vd., 2017).

İstatistiksel yöntemler, geçmiş gözlemler ve gelecekteki değerler arasında ilişki kurmak için geçmiş zaman serisi verilerini kullanır. Ancak istatistiksel modeller, aniden değişen verilerde düşük başarı gösterir. Güneş ışınımı verileri durağan değildir, bu da ani veri değişikliklerinde tahmin doğruluğunun düşmesine neden olur. Bu nedenle YSA ve destek vektör makineleri (SVM) gibi makine öğrenimi modelleri, meteorolojik parametreler kullanılarak güneş ışınımı tahmininde etkili yöntemlerdir (Sobri vd., 2018; Aguiar vd., 2016; Yadav ve Cahandel, 2014). Meenal ve Selvakumar, Hindistan’ın bazı bölgelerinde güneş ışınımı tahmini için SVM ve YSA ile deneysel modellerin performansını karşılaştırmış ve SVM’nin YSA’dan daha iyi performans gösterdiği sonucuna varmıştır (Meenal ve Selvakumar, 2018).

Farklı yöntemleri birleştiren hibrit yöntemler, istatistiksel ve fiziksel yöntemlerden herhangi birinin kombinasyonudur (Perveen vd., 2019). Bu yöntemler nispeten karmaşık olmasına rağmen, farklı modellerin avantajlarını birleştirebildikleri ve güneş ışınımı tahmini için daha fazla doğruluk elde edebildikleri için yaygın olarak kullanılmaktadırlar. Voyant ve arkadaşları, 2017 yılında yaptıkları çalışmada, hibrit modelleri kullanarak güneş ışınımı tahmin modelleri ile ilgili çalışmaların, diğer makine öğrenimi modellerine kıyasla çok daha az olduğunu gözlemlemişlerdir. Bu nedenle, gelecekteki çalışmalarda güneş ışınımını tahmin etmek için hibrit modellerin araştırılmasını önermişlerdir (Voyant vd., 2017). Böylece birçok araştırmacı, son yıllarda güneş ışınımı tahmini için farklı hibrit yöntemler uygulamıştır. Örneğin, Wang ve arkadaşları, Fransa’da yaptıkları çalışmada ileri beslemeli bir sinir ağı (FFNN) ve doğrudan açıklanabilir sinir ağının (DXNN) birleşiminden oluşan hibrit sinir ağı modelini güneş ışınımı tahmini için önermiştir (Wang vd., 2020). Gao ve arkadaşları, ABD ve Cezayir’ de yaptıkları çalışmada güneş

ışınımı tahmin edebilmek için konvansiyonel sinir ağını (CNN) ve uzun kısa süreli bellek ağını (LSTM) kullanarak yeni bir hibrit model önermiştir (Gao vd., 2020). Gala ve arkadaşları, İspanya'da yaptıkları çalışmada destek vektör regresyonu (SVR), rastgele orman (RF) ve gradyan arttırma (GB) yöntemlerinden oluşan üç farklı makine öğrenme modeli ile birlikte bir hibrit model önermiştir (Gala vd., 2016). Hassan ve arkadaşları, Orta Doğu ve Kuzey Afrika'da güneş ışınımını tahmin etmek için hibrit modellerin performansını incelemiş ve hibrit modellerin güneş ışınım tahmininde SVR ve YSA'dan daha kararlı ve doğru olduğunu göstermişlerdir (Hassan vd., 2017).

Yapay sinir ağlarında eğitim algoritmaları ve aktivasyon fonksiyonları etkili parametrelerdir. Premalatha ve Valan, sıcaklık, bağıl nem, atmosfer basıncı ve rüzgar hızı parametrelerini kullanarak gradient descent (GD), Levenberg–Marquardt (LM), resilient propagation (RP) ve scaled conjugate gradient (SCG) eğitim algoritmaları ile güneş ışınımını tahmin etmişlerdir (Premalatha ve Valan, 2016). Yadav ve Chandel, güneş radyasyonunu tahmin etmek için literatürde mevcut olan uygun yöntemleri ve araştırma boşluklarını belirlemek için YSA tabanlı teknikler üzerine bir inceleme çalışması yapmıştır. Çalışmada, çok katmanlı ileri beslemeli ağ, geri yayılım (BP) algoritması, LM öğrenme algoritması ve bir lojistik sigmoid transfer fonksiyonunun araştırmacılar tarafından yaygın olarak kullanıldığını göstermiştir (Yadav ve Cahandel, 2014). Karaman ve arkadaşları, ortalama sıcaklık, rüzgâr hızı ve güneşlenme süresi gibi giriş parametreleri ile aşırı öğrenme makinesi (ELM) modelini farklı aktivasyon ve transfer fonksiyonları kullanarak modellemiştir. Güneş ışınımı tahmininde en iyi aktivasyon fonksiyonu sin, en iyi transfer fonksiyonu tansig olarak belirlemişlerdir (Karaman vd., 2021). Khosravi ve arkadaşları, sıcaklık basınç, rüzgâr hızı ve bağıl nem parametrelerini kullanarak farklı YSA modellerinde altı eğitim algoritması (LM, BFG, RP, SCG, CGP ve BR) ve iki adet transfer fonksiyonu (tansig ve purelin) ile güneş ışınım tahmini gerçekleştirmişlerdir. LM ve BR eğitim algoritmaları ile oluşturulan çok katmanlı ileri beslemeli sinir ağı yapısıyla sırasıyla 0,9887 ve 0,9819 belirleme katsayısı değerleri ile başarılı sonuçlar elde edilmiştir (Khosravi vd., 2018).

Çalışmanın İçeriği ve Organizasyonu

Bu çalışmada, PV sistemlerde elektrik enerjisi üretimi için en önemli parametre olan güneş ışınımı, meteoroloji istasyonundan zaman serisine bağlı olarak 5 saniye aralıklarla kayıt edilen gerçek meteorolojik veriler (ortam sıcaklığı, bağıl nem, atmosferik basınç, rüzgâr hızı ve güneş ışınımı) kullanılarak YSA tabanlı çeşitli eğitim algoritmaları ve aktivasyon fonksiyonları ile tahmin edilmeye çalışılmıştır. YSA kullanılarak, zaman serisine (yıl, ay, gün, saat, dakika ve saniye) bağlı olarak elde edilen ortam sıcaklığı, bağıl nem, atmosferik basınç, rüzgâr hızı gibi meteorolojik giriş verileri ile güneş ışınımı arasındaki ilişkiyi analiz edebilen bir model geliştirildi.

Metodoloji, önerilen ağ modeli ve yapısını açıklamaktadır. Bulgular ve tartışma, önerilen modelin performansını kanıtlamak amacıyla çeşitli durum çalışmaları ve elde edilen sonuçların yorumlamalarını göstermektedir. Son bölümde ise çalışmadan elde edilen sonuçlar vurgulanmış ve irdelenmiştir.

METODOLOJİ

Çalışma Bölgesi ve Veri Seti


Bu çalışmada incelenen bölge, Doğu Anadolu Bölgesinin güneyinde yer alan 9521 km²'lik yüzölçümüne sahip, yılın belli zamanlarında yaklaşık olarak 14 saat güneşlenme süresine ve yüksek güneş ışınımı potansiyeline sahip Hakkâri ilinde yer almaktadır. Deniz seviyesinden 1755 m yükseklikte yer alan Hakkâri Üniversitesi Çölemerik Meslek Yüksekokulu yerleşkesinde yer alan Enerji Evi'nde (N:37.571799, E: 43.724936) 2018 yılı aralık ayı itibariyle Ahlborn marka Almemo 2590 Datalogger cihazı ve buna bağlı ölçüm sensörleri yer almaktadır. Bu sensörler ile 5 saniye aralıklarla ölçülen ortam sıcaklığı, bağıl nem, atmosferik basınç, rüzgâr hızı ve güneş ışınım verileri dataloggerin yanı sıra 20 çekirdekli Intel Xeon Silver işlemcisi ve 1024 Cuda içerikli Quadro P2000 ekran kartına sahip bir Workstation PC ile kayıt edilmektedir. Şekil 1' de meteorolojik veri ölçüm sensörleri ve bu verilerin kayıt edilmesini sağlayan Workstation PC yer almaktadır.

01 Ocak 2019 – 31 Aralık 2021 tarihleri arasında elde edilen veri seti bir milyon bağımsız ölçüm değerini içermekte olup veri setinin yönetimi şu şekildedir.

- **Eğitim veri seti:** Meteoroloji istasyonu tarafından ölçülen ve kaydedilen meteorolojik veriler ile güneş ışınım verilerinin 800.000 adedinin %80'inini oluşturur. Eğitimin her yenilemesinde veri seti rastgele belirlenir.
- **Doğrulama veri seti:** Eğitim veri setinde yer almayan, meteoroloji istasyonu tarafından ölçülen ve kaydedilen meteorolojik veriler ile güneş ışınım verilerinin %19'undan oluşmaktadır. Bu veriler eğitim

sırasında düzenli olarak değerlendirilir. Bir sorun olması durumunda genel bir çözüm sağlayan erken bir durdurma stratejisi uygulanır.

- **Test veri seti:** Eğitim ve doğrulama verilerinden tamamen farklı olup, farklı zaman özelliklerine sahip meteorolojik veriler ile güneş ışınım verilerinin %1'ini içerir. Eğitim tamamlandıktan sonra önerilen modelin performansını değerlendirmek için kullanılır.
- **Simülasyon veri seti:** Eğitim tamamlandıktan sonra modelin simüle edilmesi ve sonuçların karşılaştırması amacıyla oluşturulan veri setidir. Toplam veri seti içerisindeki 200.000 adet veriden oluşmaktadır. Bu 200.000 adet veri, modelin oluşturulma sürecinde yer almayıp sadece modelin simülasyonu için kullanılmıştır. Yani modelin eğitim, doğrulama ve test aşamalarında bu verilerden hiçbir tanesi bulunmamaktadır.



Şekil 1. Ölçüm Sensörleri ve Workstation PC

Meteoroloji istasyonunda kaydedilen ve eğitim, doğrulama, test ve simülasyon çalışmasında kullanılan veri setindeki bazı örnek değerler Tablo 2'de yer almaktadır.

Tablo 2. Çalışmada Kullanılan Bazı Örnek Veri Değerleri

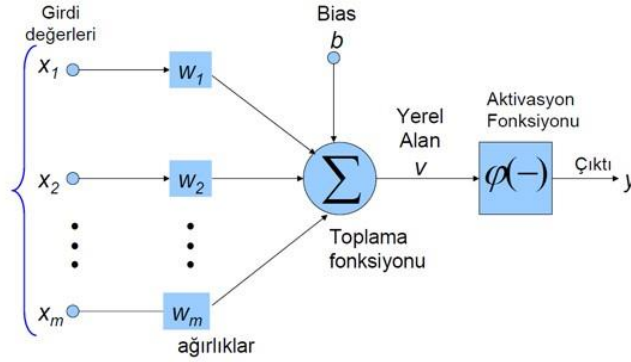
Atmosferik Basınç (mb)	Ortam Sıcaklığı (°C)	Rüzgâr Hızı (m/sn)	Bağıl Nem (%)	Güneş Işınımı (W/m ²)
823,10	16,73	0,10	50,50	310
822,70	15,88	0,60	52,10	490
822,40	16,67	0,60	49,50	680
822,50	15,29	1,50	50,30	816
827,50	20,35	0,60	33,40	987
829,20	23,19	2,20	29,50	1121

Yöntem

YSA modelleme, girdi ve hedef veriler arasında işlevsel bir ilişki kurar ve insan beyninin davranışını izleyen bir Yapay Zeka (AI) tekniğidir. YSA mimarisi genellikle bir giriş katmanı, bazı gizli katmanlar ve bir çıkış katmanı, bağlantı ağırlıkları ve önyargıları, aktivasyon fonksiyonu, transfer fonksiyonu ve toplama düğümünden oluşur. Verilerin girildiği ilk katmana girdi katmanı denir. Sinir ağında, nöron ana işlemci olarak kabul edilir. Çok katmanlı yapay sinir ağında nöronlar farklı katmanlara yerleştirilir. Diğer nöronlarla olan ilişkisine göre giriş sinyalini bir sonraki katmana aktarır. Her nöronun başka bir nöronla ilişki kurma yeteneğine nöron ağırlığı denir ve her katmandaki nöron sayısı önceki katmanların nöronlarının ağırlığına ve sayısına bağlıdır. Gizli katmanların sayısı ve ayrıca her katmandaki nöronların sayısı, oluşturulan ağın sonuçlarının doğruluğuna göre belirlenmekte ve yinelenmektedir. Giriş ve çıkış parametrelerine göre yapay sinir ağının şematik bir görünümü, modellemede kullanılan fonksiyonların rolü ve konumu Şekil 2'de gösterilmektedir. Ayrıca YSA'nın çıkış fonksiyonu ve transfer fonksiyonu sırasıyla Eşitlik 1 ve Eşitlik 2'de verilen denklem ile tanımlanabilir. Burada x ve W girdileri ve ağırlıkları, b ise sapmayı temsil eder.

$$y = W * x + b \quad (1)$$

$$trns = \sum_{m=1}^n W_m * x_m + b \quad (2)$$



Şekil 2. Modellemede Etkili Parametrelerin Performansı ve Konumu İle İlgili Nöron Diyagramının Şematik Görünümü

Bir YSA modelinde; girdiler, katmanlar ve bu katmandaki nöron sayısı, transfer fonksiyonu, eğitim algoritması gibi değişkenlerdeki herhangi bir değişiklik yeni bir YSA modeli oluşturabilir. Böylece tamamen farklı sonuçlar elde edilebilir. YSA, güneş radyasyonunu tahmin etmek için başarılı bir yöntemdir. Ayrıca, iklim değişikliği, kötü hava koşulları ve çeşitli mevsimlerde güneş radyasyonu tahmininin doğruluğunu artırmak için ek çalışmalara ihtiyaç vardır (Karaman vd., 2021; Qazi vd., 2015). Seçilen eğitim algoritması iyi bir sonuç elde etmek için önemlidir. Literatürde çok sayıda eğitim algoritması bulunmaktadır. Kullanılan eğitim algoritmasına göre, istenen çıktı ile ağ çıkışı arasındaki hata, minimum hataya ulaşılan kadar ağırlıkların değiştirilmesi için tekrar geriye doğru yayılır. Tablo 3’de çalışmada kullanılan eğitim algoritmaları ve özellikleri, Tablo 4’de ise literatürde yaygın olarak kullanılan çalışma için seçilen transfer fonksiyonları, sembolü ve matematiksel modelleri gösterilmiştir.





Tablo 3. Çalışmada Kullanılan Eğitim Algoritmaları ve Özellikleri

Eğitim Algoritması	Açıklama
Traincgb (<i>Conjugate gradient back propagation with Powell-Beale restarts</i>)	Powell-Beale yeniden başlatmaları ile eşlenik gradyan geri yayılımına göre ağırlık ve önyargı değerlerini güncelleyen bir ağ eğitim işlevidir.
Traincgp (<i>Conjugate gradient back propagation with Polak-Ribière updates</i>)	Polak-Ribière güncellemeleri ile eşlenik gradyan geri yayılımına göre ağırlık ve sapma değerlerini güncelleyen bir ağ eğitim işlevidir.
Traingd (<i>Gradient descent back propagation</i>)	Ağırlık ve sapma değerlerini gradyan inişine göre güncelleyen bir ağ eğitim işlevidir.
Traingdm (<i>Gradient descent with momentum back propagation</i>)	Ağırlık ve yanlılık değerlerini momentumlu gradyan inişine göre güncelleyen bir ağ eğitim fonksiyonudur.
Trainoss (<i>One-step secant back propagation</i>)	Ağırlık ve yanlılık değerlerini tek adımlı sekant yöntemine göre güncelleyen bir ağ eğitim işlevidir.
Trainrp (<i>Resilient back propagation</i>)	Ağırlık ve yanlılık değerlerini esnek geri yayılım algoritmasına (Rprop) göre güncelleyen bir ağ eğitim işlevidir.
Trainscg (<i>Scaled conjugate gradient back propagation</i>)	Ölçeklenmiş eşlenik gradyan yöntemine göre ağırlık ve yanlılık değerlerini güncelleyen bir ağ eğitim işlevidir.
Trainlm (<i>Levenberg-Marquardt back propagation</i>)	Levenberg-Marquardt optimizasyonuna göre ağırlık ve bias değerlerini güncelleyen bir ağ eğitim fonksiyonudur. En hızlı geri yayılım algoritmasıdır ve diğer algoritmalarından daha fazla bellek gerektirmesine rağmen, denetimli algoritma olarak kullanılması tavsiye edilir.

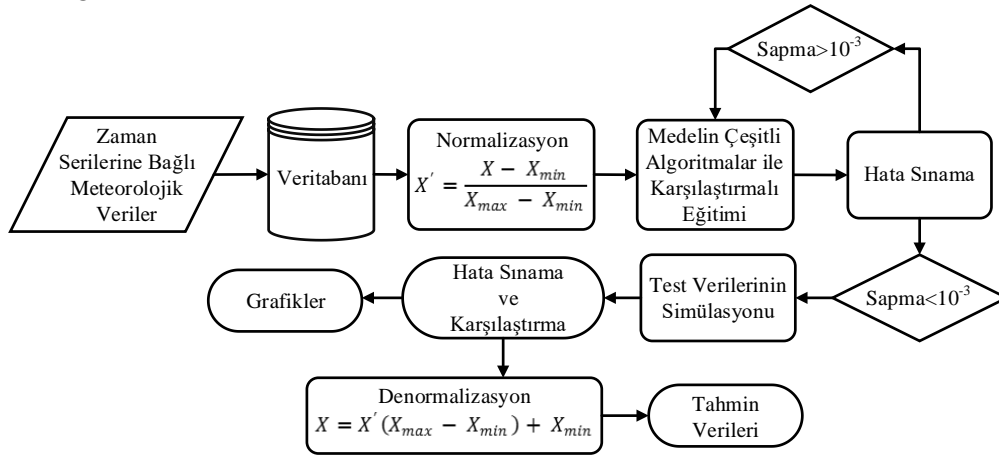
YSA teknikleri, geleneksel tekniklere alternatif yöntemler haline gelmiştir ve birçok güneş enerjisi uygulamasında kullanılmaktadır (Gairaa vd., 2016; Kumar ve Kaur, 2016; Yadav vd., 2014). Güneş enerji santralleri için önemli bir parametre olan güneş ışınımının yeryüzüne ulaşması farklı meteorolojik koşullara bağlıdır. Bu nedenle literatürde elde edilebilir meteorolojik parametreler yaygın olarak kullanılarak birçok çalışma gerçekleştirilmiştir (Faisal vd., 2022; Karaman vd., 2021; AlSkaif vd., 2020; Marzouq vd., 2019; Premalatha ve Naveen, 2018; Yadav vd., 2014). Bu nedenle, YSA’nın giriş katmanında, istasyonda ölçülen ortam sıcaklığı, bağıl nem, atmosferik basınç ve rüzgâr

hızı verileri ile gerçekleşme zaman değerleri (gün, ay, yıl, saat, dakika, saniye) kullanılırken, çıkış katmanında ise güneş ışınım verileri eğitim ve tahminleme için kullanılmıştır.

Tablo 4. Çalışmada Kullanılan Transfer Fonksiyonları ve Matematiksel Modelleri

Transfer Fonksiyonu	Sembolü	Matematiksel Modeli
Logsig (Log-sigmoid transfer function)		$Logsig = \frac{1}{1 + e^{-x}}$
Tansig (Hyperbolic tangent sigmoid transfer function)		$Tansig = \frac{2}{(1 + e^{-2x})^{-1}}$
Purelin (Linear transfer function)		$Purelin(x) = x$
Poslin (Positive linear transfer function)		$Poslin(x) = x, \text{ eğer } x > 0$ $Poslin(x) = 0, \text{ eğer } x \leq 0$

Çalışmada kullanılan YSA modeli, Workstation üzerine kurulu MATLABR2021a arayüzünde Simulink kütüphanesinde yer alan NNTtoolbox yardımıyla oluşturulmuştur. Geniş kapsamlı ağ oluşumuna serbest bir şekilde imkân tanıyan kütüphane, hesaplama sırasında paralel işlem kullanımına da imkân tanımaktadır. Ayrıca, kolay ve hızlı uygulanabilir parametrik yapısı sayesinde, birçok farklı ağ yapısının hızlıca değerlendirilmesi ve veri setine optimum kombinasyonun seçilebilmesine imkan tanımaktadır. Daha küçük ağ yapıları üzerinden hızlıca değerlendirmeye alınan veriler en iyi kombinasyonların seçilmesinin ardından daha geniş ağlarda test edildikten sonra nihai test sonuçları elde edilmiştir. Güneş ışınımının tahmin edilmesi için oluşturulan modelin genel akış diyagramı Şekil 3'de gösterilmiştir.

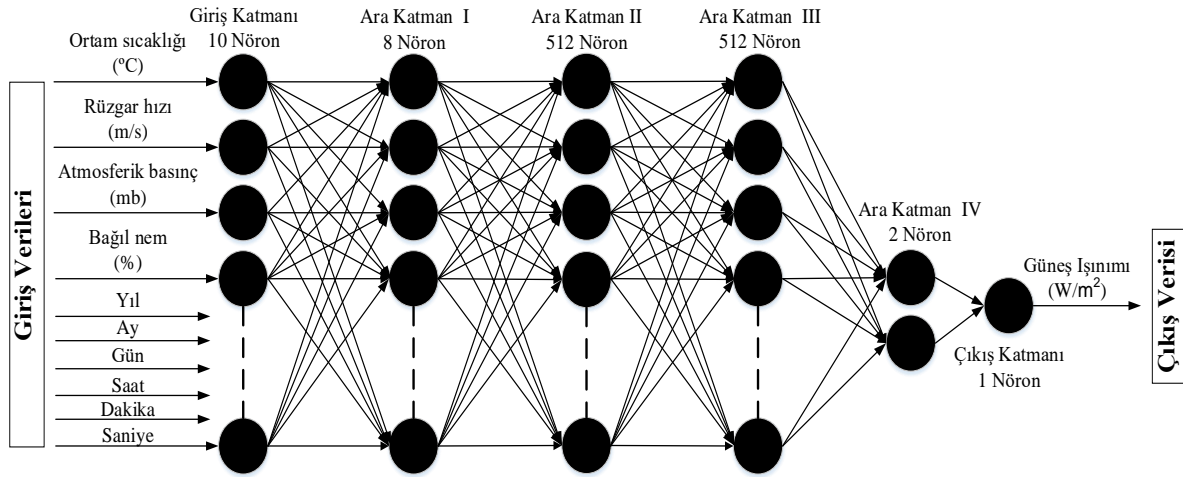


Şekil 3. Çalışmada Kullanılan Sistemin Akış Diyagramı

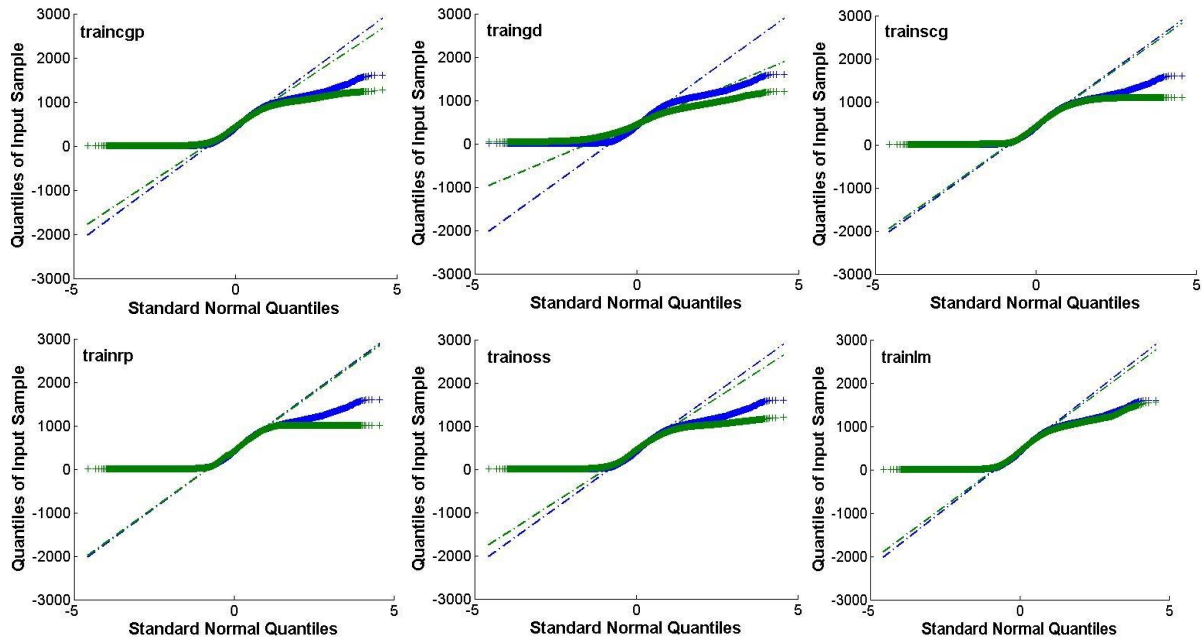
Meteoroloji istasyonu tarafından ölçülen ve kaydedilen meteorolojik veriler MATLAB kütüphanesine yüklendikten sonra normalizasyon işlemi gerçekleştirilmiştir. Meteoroloji istasyonuna bağlı sensörler tarafından ölçülen ve kaydedilen her bir veri, kendi kümesindeki en büyük (X_{max}) ve en küçük (X_{min}) değerlere bağlı olarak -1 ve 1 aralığına daraltılmıştır (Bamisile vd., 2022; Arthur, Temeng ve Ziggah, 2020; Vakili vd., 2017; Premalatha ve Valan Arasu, 2016). Verilerin normalizasyonunun ardından çeşitli parametrelere sahip bir ağ oluşturulmuştur. Bu ağın ilk katmanında giriş parametreleri, çıkış katmanında ise güneş ışınım değeri yer almaktadır. Ağın ilk ara katmanında 1 adet 8, ikinci ve üçüncüsünde 2 adet 512 ve dördüncü katmanında 1 adet 2 nörona sahip olmak üzere 6 katmanlı bir ağ modeli yer almaktadır. Ara katmanın üçüncü ve dördüncü katmanında sırasıyla aktivasyon fonksiyonları (logsig, poslin, purelin ve tansig) ve model için kullanılan hesaplama algoritması (traincgp, traingd, trainscg, trainrp, trainoss, trainlm) kullanılmıştır. YSA modeli farklı katmanlarda ve farklı nöron sayılarında geliştirilmiş ve en başarılı yapı belirlenmeye çalışılmıştır. Ayrıca ağ yapısı tamamen bilgisayar donanımına bağlı olarak her eğitimin 8 iterasyon yaptırılması sonucunda en başarılı ortalama sonuca göre oluşturulmuştur. Böylece rastgele seçilen veri setinin neden olacağı şans faktörünün etkisi de ortadan kaldırılmaya çalışılmıştır. Şekil 4'de, giriş, çıkış ve her bir ara katmanda sırasıyla 8, 512, 512 ve 2 nörona sahip YSA modeli gösterilmiştir.

Çalışmada kullanılan veri seti bir milyon adet bağımsız ölçümü içermektedir. Veri seti içerisinde 800.000 adet veri rastgele seçilmiş olarak eğitim, doğrulama ve test için, geri kalan 200.000 adet veri ise simülasyon aşamalarında kullanılmıştır. İçerikteki her bir veri Şekil 4' de görüldüğü gibi bir önceki ve bir sonraki nörona bağlı olarak üzerinde

ve ara bağlantılarda veri tutmaktadır. Kullanılan eğitim algoritmasına bağlı olarak bu değerler üzerinden güncelleme yaparak her veri setinin bilgisini üzerinde depolamaktadır. Veri setinin çeşitliliği ve her bir veri satırının etki değerinin düşüklüğüne göre eğitim daha kaliteli olmaktadır. MATLAB kütüphanesinde bulunan algoritmalarından faydalanılarak çeşitli denemeler yapılmıştır. Seçilen eğitim algoritması iyi bir sonuç elde etmek için önemlidir. Literatürde çok sayıda eğitim algoritması bulunmaktadır (Arthur vd., 2020). Kullanılan eğitim algoritmasına göre, istenen çıktı ile ağ çıkışı arasındaki hata, minimum hataya ulaşılan kadar ağırlıkların değiştirilmesi için tekrar geriye doğru yayılır. Matlab resmi web sayfasında da “*trainlm*” algoritmasının kullanılması şiddetle tavsiye edilmektedir. Bu durum dikkate alındığında “*trainlm*” algoritmasının çalışılan veri seti üzerinde başarılı sonuçlar ortaya çıkardığı tespit edilmiş ve ağda bu algoritma ile eğitim yapılmasına karar verilmiştir. Farklı eğitim algoritmaları ile “*logsig*” aktivasyon fonksiyonu kullanılarak yapılan çalışmada güneş ışınımının gerçek ve tahmin değerlerinin karşılaştırmasını içeren veri setleri için qq-plot grafiği Şekil 5’de yer almaktadır.

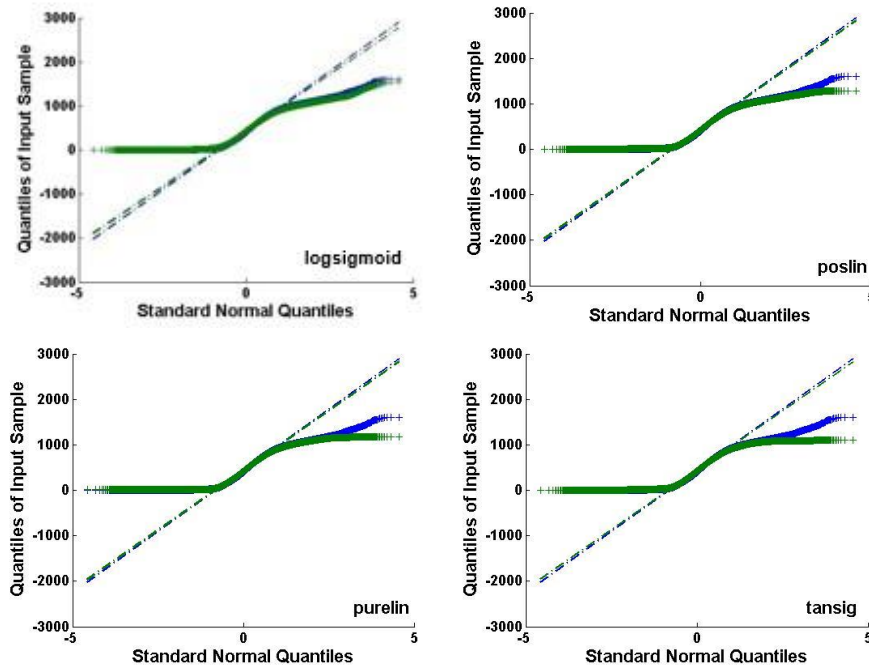


Şekil 4. Çalışmada Kullanılan YSA Modeli



Şekil 5. Eğitim Algoritmalarına Göre Güneş Işınımının Gerçek ve Tahmin Değerlerinin Karşılaştırılması

qq-plot grafikleri incelendiğinde, tahmin sonuçları ile gerçek değerler arasında en yakın ilişki “*trainlm*” eğitim algoritması ile yapılan çalışmada görülmektedir. Yapılan tahminin başarısını gösteren grafikte yeşil noktalar tahmin değerlerini, mavi noktalar ise meteoroloji istasyonunda eş zamanlı olarak ölçülen gerçek güneş ışınım verileridir. Sapma çizgileri arasındaki açıklık dikkate alındığında, tahmin ve gerçekleşme değerleri arasında kabul edilebilir bir yakınlığın olduğu görülmektedir. Ayrıca veriler arasındaki bağlantı, aradaki farka rağmen benzer bir hızda devam etmektedir. Bu, ağırlık sapma oranının kararlı olduğunu göstermektedir.



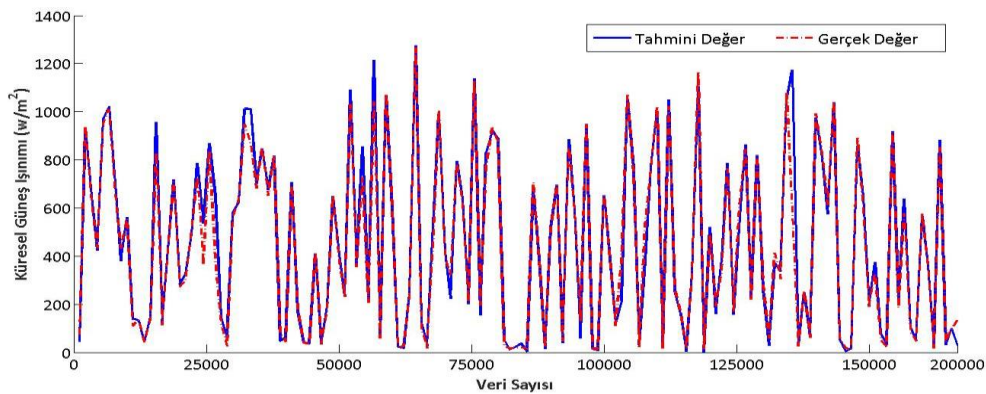
Şekil 6. Aktivasyon Fonksiyonlarına Göre Gerçek Işınm İle Tahmini Işınm Değerlerinin Karşılaştırılması

Modelde kullanılan diğer bir parametre olan aktivasyon fonksiyonu, MATLAB kütüphanesinde yer alan çeşitli fonksiyonların test edilerek en uygun bulunan fonksiyonun seçilmesi sonucu çalışmaya eklenmiştir. “*poslin*” fonksiyonu bu kapsamda, çalışılan veri seti üzerinde en başarılı fonksiyon olarak tespit edilmiş ve ağı eğitim sürecinde bu fonksiyon kullanılmıştır. En başarılı eğitim algoritması olan “*trainlm*” ile aktivasyon fonksiyonlarının karşılaştırılmasını içeren qq-plot grafiği Şekil 6’da yer almaktadır. Tablo 7’de gösterildiği gibi, “*trainlm*” eğitim algoritması ile “*poslin*” aktivasyon fonksiyonu kullanılarak oluşturulan modelde %98,84’ lük bir başarı elde edilmiştir.

BULGULAR VE TARTIŞMA

Performans Değerlendirmesi

Meteoroloji istasyonu tarafından ölçülen ışınım değerleri ile oluşturulan model tarafından tahmin edilen sonuçlar Şekil 7’de gösterilmiştir. Tahmin ve gerçek ışınım değerleri arasındaki hata oranı %1 ile %4 arasında değişmektedir.



Şekil 7. Ölçülen Güneş Işınım Verileri İle Tahmin Verileri Arasındaki Fark

Bu çalışmada, tahmin edilen küresel güneş ışınımı, ölçülen verilerle karşılaştırılarak modelin performansı değerlendirilmiştir. Tahmin performansı, bir modelin kullanılan diğer herhangi bir modelden nasıl daha iyi performans gösterdiğini analiz etmenin basit bir yolu olarak sunulur. Tahmin sonuçlarının ne kadar iyi olduğunu ve mümkün olan en iyi yapıyı nicel olarak belirlemek için en çok kabul gören standart değerlendirme ölçütlerinden

ortalama sapma hatası (MBE), ortalama mutlak hata (MAE), ortalama kare hatası (MSE), kök ortalama kare hatası (RMSE) ve normalize kök ortalama kare hatası (nRMSE) kullanılmaktadır (Ağbulut vd., 2021; Yang vd., 2018; Voyant vd., 2017). Bu istatistiksel metrikler, denklemleri ve açıklamaları Tablo 5’de verilmiştir.

Tablo 5. Çalışmada Kullanılan İstatistiksel Metriklerin Özeti

Metrik	Denklem	Açıklama
MBE	$MBE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)$	Tahmin modellerinin uzun vadeli performansı için önemli bir ölçümdür. MBE'nin küçük değeri, tahmin modelinin daha iyi performansa sahip olduğunu gösterir. Pozitif MBE, hesaplanan değerde fazla tahmin anlamına gelir. Negatif MBE, hesaplanan değerdeki eksik tahmini gösterir.
MAE	$MAE = \frac{1}{N} \sum_{i=1}^N y_i - \hat{y}_i $	Tahmin edilen değerlerin ölçülen değerlere ne kadar yakın olduğunu ölçmek için kullanılan bir değerdir.
MSE	$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$	Sinir ağının eğitim sürecinde ürettiği hedef ve çıktı arasındaki farkı bulmak için kullanılır. MSE genellikle eğitim algoritması tarafından en aza indirilen parametredir.
RMSE	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$	RMSE, tahmin modellerinin kısa vadeli performansı hakkında bilgi sağlar. Değeri her zaman pozitifdir ve sifıra yakın olması istenir.
nRMSE	$nRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}}{\bar{y}_i} * 100$	RMSE ve ölçülen verilerin ortalama değeri ile elde edilir. nRMSE'nin küçük olması, kullanılan tahmin modelinin daha iyi performansa sahip olduğunu gösterir. Tahmin modelinin başarısı, şu şekilde kabul edilir. Mükemmel tahmin: nRMSE<%10 İyi tahmin: %10<nRMSE<20% Orta tahmin: 20%<nRMSE<30% Kötü tahmin: nRMSE>%30
R ²	$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2}$	Bir modelin bir dizi ölçülen veriyi ne kadar iyi tahmin edebileceği hakkında bilgi sağlar. Değeri 0 ile 1 arasında değişmektedir. R ² değerinin 1'e yaklaşması daha iyi performansın göstergesidir.

Ölçülen ve tahmin edilen veriler arasındaki ilişkiyi kontrol etmek için, genellikle Tablo 5’de ifade edilen belirleme katsayısı (R²) hesaplayan istatistiksel bir yöntem kullanılır. R²'nin ortalama karekökü olan korelasyon katsayısı (R) ise, 0 ile +1 arasında bir sayıdır ve iki değişken arasındaki ilişki derecesini ölçer. Ölçülen ve tahmin edilen veriler arasında iyi bir doğrusal ilişki olup olmadığı bu şekilde çıkarılabilir (R = 0 veya R = 1 durumu). Tablo 5’de gösterilen denklemlerde N, veri sayısını, y_i, gerçek ışınım değerini, \hat{y}_i , tahmin edilen ışınım değerini, \bar{y}_i ise ortalama güneş ışınım değerini ifade eder.

Meteoroloji istasyonunda ölçülen güneş ışınım değerleri ile tahmin edilen değerlerin doğruluğunun belirlenmesi için MBE, MAE, MSE, RMSE ve nRMSE istatistik yöntemleri kullanılmıştır. Simülasyon aşamasında tahminlenen 200.000 adet veri üzerinden yapılan başarı oranı en yaygın hata sınama yöntemi olan MSE üzerinden değerlendirilmiştir. Oluşturulan model optimizasyon amacı ile farklı algoritmalar üzerinden test edilmiş ve kullanılan birçok algortmada benzer yakınlıkta başarı değerlerinin elde edildiği tespit edilmiştir. Tablo 6’da farklı eğitim algoritmaları ile literatürde yaygın olarak kullanılan aktivasyon fonksiyonu “*logsig*” kullanılarak oluşturulan modelden elde edilen veriler doğrultusunda hesaplanan hata sınama yöntemlerinin sonuçları yer almaktadır.

“*logsig*” aktivasyon fonksiyonu ile algoritmaların karşılaştırılması sonucu çalışmadaki en büyük başarının “*trainscg*” üzerinden elde edildiği Tablo 6’da görülmektedir. Farklı eğitim algoritmaları ile oluşturulan birçok modelde korelasyon katsayısının 1’ e yakın değerlerde olması, gerçek ve tahmin değerleri arasında kesin bir doğrusal ilişki olduğunu gösterir. Farklı eğitim algoritmaları ile oluşturulan modellerin birçoğu %5’in altında bir hata oranına sahip olmasına rağmen “*trainscg*” eğitim algoritması ile oluşturulan YSA modeli %1,78’ lik MSE ve %19,37 nRMSE değeri ile iyi derecede bir performans göstermektedir. Ancak Tablo 7’de görüldüğü gibi “*trainlm*” eğitim algoritması ile “*poslin*” aktivasyon fonksiyonu kullanılarak yapılan çalışma sonucunda daha başarılı sonuçlar elde edilmiştir.

Tablo 7’de eğitim algoritmaları arasında en başarılı olan “*trainlm*” ile farklı aktivasyon fonksiyonları kullanılarak elde edilen verilerle hesaplanan hata sınama yöntemlerine ait sonuçlar yer almaktadır. Bu sonuçlar üzerinden “*poslin*”

aktivasyon fonksiyonu ile elde edilen modelin %1,16 MSE ve yaklaşık olarak %8,81'lik bir nRMSE değerine sahip olması gerçek ve tahmin değerlerinin birbiri ile olan yakınlığını ve başarılı bir tahmin sonucuna ulaşıldığını göstermektedir.

Tablo 6. Farklı Algoritmalarla “logsig” Aktivasyon Fonksiyonu Kullanılarak Elde Edilen İstatistiksel Sonuçlar

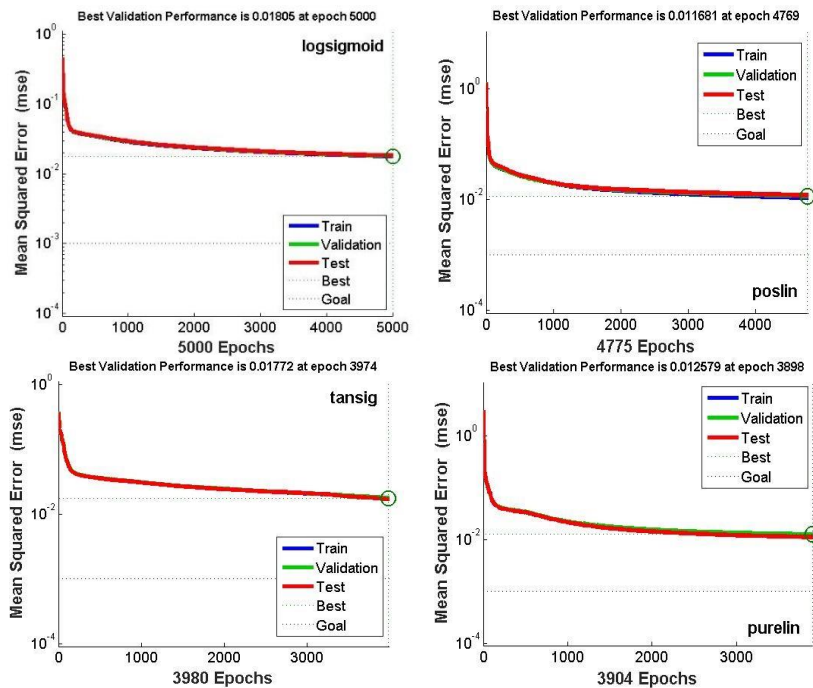
	MBE	MAE	MSE	RMSE	nRMSE	R ²
Traincgb	-0,0002	0,0864	0,0232	0,1121	0,2606	0,94614
Traincgp	0,0002	0,1069	0,0317	0,1221	0,2839	0,92589
Traingd	-0,0050	0,2776	0,1200	0,3464	0,8055	0,67164
Traingdm	-0,0024	0,3299	0,1568	0,3421	0,8379	0,53395
Trainoss	-0,0024	0,1233	0,0385	0,1421	0,3304	0,90822
Trainrp	0,0000	0,0809	0,0202	0,0921	0,2141	0,95725
Trainscg	0,0005	0,0741	0,0178	0,0833	0,1937	0,95917
Trainlm	0,0007	0,0732	0,0181	0,0844	0,1962	0,95861

Tablo 7. “trainlm” Algoritması İle Farklı Aktivasyon Fonksiyonları Kullanılarak Elde Edilen İstatistiksel Sonuçlar

	MBE	MAE	MSE	RMSE	nRMSE	R ²
Logsig	0,0007	0,0732	0,0181	0,0833	0,1962	0,95861
Tansig	0,0005	0,0741	0,0178	0,0844	0,1937	0,95917
Purelin	0,0005	0,0539	0,0124	0,0512	0,1190	0,97251
Poslin	0,0007	0,0513	0,0116	0,0379	0,0881	0,95467

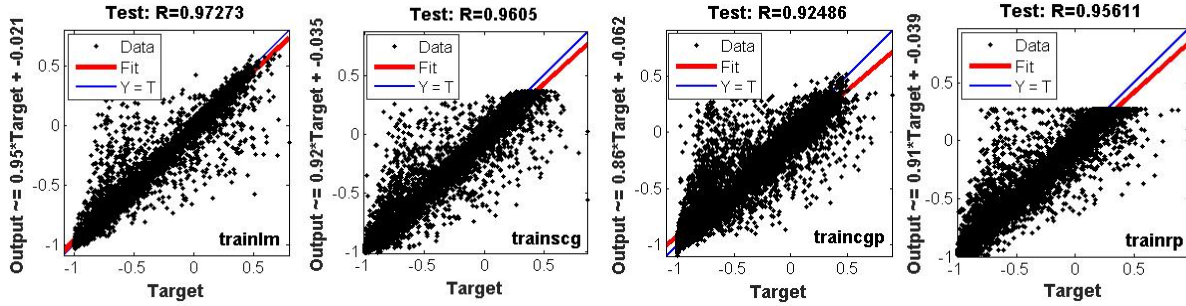
Bu çalışmada, Hakkâri Üniversitesi ÇMYO Enerji evinde bulunan meteoroloji istasyonu kullanılarak elde edilen ölçüm verileri ile bağıl nem, sıcaklık, basınç ve gerçekleşme zaman değerlerinin güneş ışınımı üzerindeki etkileri yapay sinir ağı algoritmaları kullanılarak incelenmiştir.

Oluşturulan modelde en iyi sonucu veren “trainlm” eğitim algoritması ile farklı aktivasyon fonksiyonlarının kullanılması ile elde edilen performans grafikleri Şekil 8’ de gösterilmiştir. Bu performans grafikleri simülasyon verisi olan 200.000 adet veri kullanılarak elde edilmiştir. “trainlm” eğitim algoritması ve “poslin” aktivasyon fonksiyonunun birlikte kullanıldığı model %1,16 performans değeri ile en iyi sonucu 4769. döngüde göstermiştir. Aslında “trainlm” eğitim algoritması ile birlikte tercih edilen aktivasyon fonksiyonlarının sonuçlarının başarılı performans değerleri gösterdiği söylenebilir. Ancak eğitim algoritmaları performans değerini ciddi anlamda değiştirmektedir.



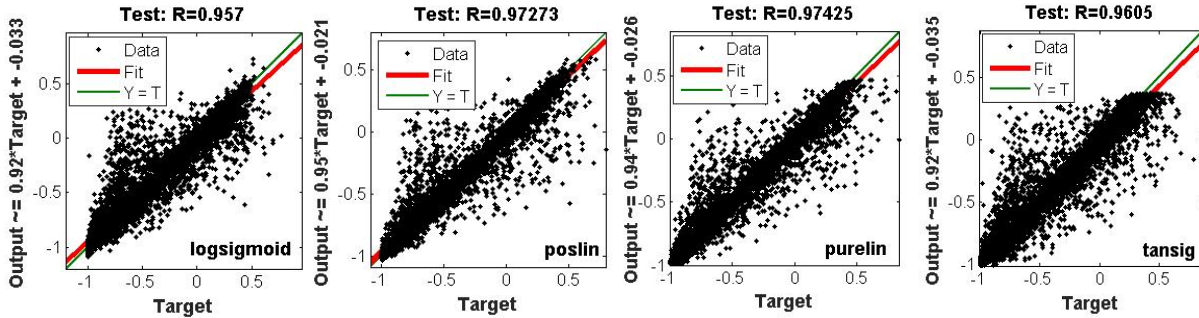
Şekil 8. Aktivasyon Fonksiyonlarının Test Aşamasına Ait Performans Grafikleri

Yapılan çalışma, MATLAB yazılımındaki NNToolbox kullanılarak oluşturulan modelde simüle edilmiş ve bu model yardımıyla grafikler oluşturulmuştur. Eğitimdeki döngülerden elde edilen düzeltmeler, eğitim ve doğrulama aşamasında başarı oranında artış sağlarken, test aşamasında bu tür düzeltmeler yapılmamaktadır. Bu nedenle, test aşamasındaki yüksek başarı, daha önemli sonuçların ortaya çıkmasına neden olur. “*poslin*” aktivasyon fonksiyonu ile en başarılı dört farklı eğitim algoritmasının kullanılarak test sonuçlarının elde edildiği regresyon grafikleri Şekil 9’da görülmektedir.



Şekil 9. En Başarılı Dört Farklı Eğitim Algoritmasının Test Aşamasına Ait Regresyon Grafikleri

Şekil 9’da en başarılı dört farklı eğitim algoritması kullanılarak yapılan çalışmada test verilerine göre en başarılı algoritma yaklaşık %97 başarı oranı ile “*trainlm*” algoritması ve “*poslin*” aktivasyon fonksiyonu olmaktadır. Ancak bu eğitim algoritması ile farklı aktivasyon fonksiyonları kullanılarak yapılan çalışmada başarı oranı daha da yükselmektedir. Özellikle “*purelin*” ve “*poslin*” aktivasyon fonksiyonları tahmin başarısını yaklaşık %1 oranında yükseltmektedir. Farklı aktivasyon fonksiyonları ile “*trainlm*” eğitim algoritmasının test sonuçlarına ait regresyon grafikleri Şekil 10’da gösterilmiştir.



Şekil 10. Aktivasyon Fonksiyonlarının Test Aşamasına Ait Regresyon Grafikleri

Çalışmada kullanılan veri sayısı çok yüksek değerlerde olduğundan Şekil 9 ve Şekil 10’deki grafiklerde regresyon dağılımları yoğun görülmektedir. Bu durum verilerin grafik üzerindeki dağılımının gözlemlenmesini zorlaştırmaktadır. Ancak grafikte görülmekte olan ‘fit’ eğrileri ile ‘Y=T’ eğrileri arasındaki açı sapma oranını gösterdiğinden veri yoğunluğunun durumu bu açıdan gözlemlenebilmektedir. Bu açının küçülmesi oranında sonuçlar arasındaki yakınlık büyümektedir. İki eğrinin paralel olması durumunda ise ölçüm değeri ile tahmin değerleri eşit olmaktadır. Bu iki çizgi arasındaki açısal değerden de anlaşılacağı üzere “*poslin*” aktivasyon fonksiyonu ile oluşturulan modelde tahmin değerleri ile gerçek değerler arasında çok yakın bir ilişki bulunmaktadır.

Çalışmanın başarı değerinin yorumlanabileceği diğer bir nokta ise, Şekil 9 ve Şekil 10’deki grafikler üzerindeki ‘R’ değerleridir. R değerinin 1’e yakın olması başarı oranının yüksek olduğunu göstermektedir. R’nin 1 olması durumunda ise her iki eğri paralel olmakta ve tüm veri noktaları ‘Y=T’ eğrisi üzerine toplanmaktadır. Bu durumda %100’lük bir başarı ile tüm tahmin değerleri, gerçek değerler ile birebir eşleşmiş olmaktadır. Tablo 8’de, eğitimin tüm aşamalarında, çalışmada kullanılan tüm eğitim algoritmaları ve aktivasyon fonksiyonlarının regresyon analizi üzerinden yapılan başarı değerleri gösterilmiştir. Zaman serisine bağlı meteorolojik veriler kullanılarak güneş ışınım tahmininde en iyi sonuç, %97,467 başarı oranı ile “*trainlm*” algoritması ve “*poslin*” aktivasyon fonksiyonu kullanılarak oluşturulan model ile elde edilmiştir. Bütün eğitim algoritmaları içerisinde özellikle “*traingd*” ve “*traingdm*” algoritmaları başarılı sonuçlar gösterememiştir. Bunun nedeni, oluşturulan ağ yapısının ağırlık ve sapma değerlerini gradyan inişine göre güncelleyememesinden kaynaklanmaktadır.

Tablo 8. Eğitimin Tüm Aşamalarında Farklı Eğitim Algoritmaları ve Aktivasyon Fonksiyonları Kullanılarak Regresyon Analizi Üzerinden Elde Edilen Başarı Değerleri

	Logsig	Tansig	Purelin	Poslin
Traincgb	%94,614	%94,817	%95,116	%94,529
Traincgp	%92,589	%92,892	%92,136	%92,486
Traingd	%67,164	%67,314	%68,662	%68,697
Traingdm	%53,395	%53,893	%53,931	%54,215
Trainoss	%90,822	%91,022	%91,973	%91,996
Trainrp	%95,725	%96,213	%96,865	%96,451
Trainscg	%95,700	%96,050	%90,778	%97,273
Trainlm	%95,861	%95,917	%97,251	%97,467

SONUÇ

Meteorolojik veriler, güneş ışınım değerinin öngörülmesine olanak tanıyan önemli ilişkileri içerisinde barındırır. Bu nedenle güneş ışınımının belirlenmesinde simülasyon yoluyla elde edilen sonuçlar, güneş ışınımının daha iyi tahmin edilmesini sağlar. Bu çalışmada, zaman serilerine bağlı olarak 5 saniye aralıklarla ölçülen ve kaydedilen meteorolojik veriler kullanılarak güneş ışınımının belirlenmesine yönelik YSA tabanlı modeller kullanılmış ve bu modellerin başarı oranları karşılaştırılmıştır. Güneş ışınımının tahmininde kullanılan farklı eğitim algoritmaları ve aktivasyon fonksiyonları ile değişik YSA modelleri oluşturulmuş ve başarı oranı en yüksek model belirlenmiştir. Elde edilen bulgular sonucunda “*trainlm*” algoritması ve “*poslin*” aktivasyon fonksiyonu kullanılarak oluşturulan model, %97,467 başarı oranı ile meteorolojik veriler kullanılarak güneş ışınım tahmininde en başarılı model olmuştur. “*traingd*” ve “*traingdm*” algoritmalarının dışındaki algoritmalar ile elde edilen sonuçlardaki korelasyon katsayısı (R) oranlarının da %10’ u geçmediği görülmektedir. Eğitim algoritmalarının yanı sıra aktivasyon fonksiyonlarında tahmin başarısı üzerinde etkili olduğu görülmektedir. Modelin doğruluğu göz önüne alındığında, modelin dünyanın herhangi bir yerindeki güneş ışınımının değerlendirilmesi için genelleştirilmesi olasıdır.

Kullanılan meteorolojik ölçüm değerlerinin bir alanda var olması durumunda, güneş ışınım değerlerinin bu alanda ölçüme gerek kalmadan, kullanılan modele bağlı bir yapay zekâ uygulaması üzerinden tahmin yolu ile büyük bir başarı oranında elde edilebileceği çalışma sonucunda gösterilmiştir. Güneş ışınım cihazlarının pahalı olması, lisans ve kalibrasyon sorunlarının bulunması ışınım değerlerinin elde edilmesini zorlaştırmaktadır. Bu nedenle oluşturulan model ile daha az maliyetli sistemlerle güneş ışınım değerlerinin kabul edilebilir sınırlar içerisinde tahmin edilmesi sağlanmıştır.

KAYNAKLAR

- Aguiar, L. M., Pereira, B., Lauret, P., Díaz, F., & David, M. (2016). Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting. *Renewable Energy*, 97, 599-610.
- AlSkaif, T., Dev, S., Visser, L., Hossari, M., & van Sark, W. (2020). A systematic analysis of meteorological variables for PV output power estimation *Renewable Energy*, 153, 12-22.
- Arthur, C. K., Temeng, V. A., & Ziggah, Y. Y. (2020). Performance evaluation of training algorithms in backpropagation neural network approach to blast-induced ground vibration prediction, *Ghana Mining Journal*, 20(1), 20-33.
- Ağbulut, Ü., Gürel, A. E., & Biçen, Y. (2021). Prediction of daily global solar radiation using different machine learning algorithms: Evaluation and comparison. *Renewable and Sustainable Energy Reviews*, 135, 110114.
- Bamisile, O., Oluwasanmi, A., Ejayi, C., Yimen, N., Obiora, S., & Huang, Q. (2022). Comparison of machine learning and deep learning algorithms for hourly global/diffuse solar radiation predictions. *International Journal of Energy Research*, 46(8), 10052-10073.
- Cornaro, C., Bucci, F., Pierro, M., Del Frate, F., Peronaci, S., & Taravat, A. (2015). Twenty-Four Hour Solar Irradiance Forecast Based on Neural Networks and Numerical Weather Prediction. *Journal of Solar Energy Engineering*, 137(3).

- Faisal, A. F., Rahman, A., Habib, M. T. M., Siddique, A. H., Hasan, M., & Khan, M. M. (2022). Neural networks based multivariate time series forecasting of solar radiation using meteorological data of different cities of Bangladesh. *Results in Engineering*, 13, 100365.
- Gala, Y., Fernández, Á., Díaz, J., & Dorronsoro, J. R. (2016). Hybrid machine learning forecasting of solar radiation values. *Neurocomputing*, 176, 48-59.
- Gairaa, K., Khellaf, A., Messlem, Y., & Chellali, F. (2016). Estimation of the daily global solar radiation based on Box-Jenkins and ANN models: A combined approach. *Renewable and Sustainable Energy Reviews*, 57, 238-249.
- Gao, B., Huang, X., Shi, J., Tai, Y., & Zhang, J. (2020). Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks. *Renewable Energy*, 162, 1665-1683.
- Hassan, M. A., Khalil, A., Kaseb, S., & Kassem, M. A. (2017). Exploring the potential of tree-based ensemble methods in solar radiation modeling. *Applied Energy*, 203, 897-916.
- Huang, X., Li, Q., Tai, Y., Chen, Z., Zhang, J., Shi, J., & Liu, W. (2021). Hybrid deep neural model for hourly solar irradiance forecasting. *Renewable Energy*, 171, 1041-1060.
- IRENA (2021), Renewable Energy Statistics 2021. The International Renewable Energy Agency, Abu Dhabi.
- Joshi, B., Kay, M., Copper, J. K., & Sproul, A. B. (2019). Evaluation of solar irradiance forecasting skills of the Australian Bureau of Meteorology's ACCESS models. *Solar Energy*, 188, 386-402.
- Kumar, S., & Kaur, T. (2016). Development of ANN based model for solar potential assessment using various meteorological parameters. *Energy Procedia*, 90, 587-592.
- Khosravi, A., Koury, R. N. N., Machado, L., & Pabon, J. J. G. (2018). Prediction of hourly solar radiation in Abu Musa Island using machine learning algorithms. *Journal of Cleaner Production*, 176, 63-75.
- Karaman, Ö. A., Ađır, T. T., & Arsel, İ. (2021). Estimation of solar radiation using modern methods. *Alexandria Engineering Journal*, 60(2), 2447-2455.
- Lu, N., Qin, J., Yang, K., & Sun, J. (2011). A simple and efficient algorithm to estimate daily global solar radiation from geostationary satellite data. *Energy*, 36(5), 3179-3188.
- Lima, F. J., Martins, F. R., Pereira, E. B., Lorenz, E., & Heinemann, D. (2016). Forecast for surface solar irradiance at the Brazilian Northeastern region using NWP model and artificial neural networks. *Renewable Energy*, 87, 807-818.
- Molina, A., Falvey, M., & Rondanelli, R. (2017). A solar radiation database for Chile. *Scientific Reports*, 7(1), 1-11.
- Meenal, R., & Selvakumar, A. I. (2018). Assessment of SVM, empirical and ANN based solar radiation prediction models with most influencing input parameters. *Renewable Energy*, 121, 324-343.
- Marzouq, M., Bounoua, Z., El Fadili, H., Mechaqrane, A., Zenkour, K., & Lakhliai, Z. (2019). New daily global solar irradiance estimation model based on automatic selection of input parameters using evolutionary artificial neural networks. *Journal of Cleaner Production*, 209, 1105-1118.
- Othman, A. B., Belkilani, K., & Besbes, M. (2020). Prediction improvement of potential PV production pattern, imagery satellite-based. *Scientific Reports*, 10(1), 1-10.
- Premalatha, M., & Naveen, C. (2018). Analysis of different combinations of meteorological parameters in predicting the horizontal global solar radiation with ANN approach: A case study. *Renewable and Sustainable Energy Reviews*, 91, 248-258.
- Perveen, G., Rizwan, M., & Goel, N. (2019). Comparison of intelligent modelling techniques for forecasting solar energy and its application in solar PV based energy system. *IET Energy Systems Integration*, 1(1), 34-51.
- Premalatha, N., & Valan Arasu, A. (2020). Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms. *Journal of Applied Research and Technology*, 14(3), 206-214.
- Qazi, A., Fayaz, H., Wadi, A., Raj, R. G., Rahim, N. A., & Khan, W. A. (2015). The artificial neural network for solar radiation prediction and designing solar systems: a systematic literature review. *Journal of Cleaner Production*, 104, 1-12.

- Sobri, S., Koochi-Kamali, S., & Rahim, N. A. (2018). Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management*, 156, 459-497.
- Tuohy, A., Zack, J., Haupt, S. E., Sharp, J., Ahlstrom, M., Dise, S., & Collier, C. (2015). Solar forecasting: methods, challenges, and performance. *IEEE Power and Energy Magazine*, 13(6), 50-59.
- Vakili, M., Sabbagh-Yazdi, S. R., Khosrojerdi, S., & Kalhor, K. (2017). Evaluating the effect of particulate matter pollution on estimation of daily global solar radiation using artificial neural network modeling based on meteorological data. *Journal of Cleaner Production*, 141, 1275-1285.
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C., Motte, F., & Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105, 569-582.
- Wang, H., Cai, R., Zhou, B., Aziz, S., Qin, B., Voropai, N., & Barakhtenko, E. (2020). Solar irradiance forecasting based on direct explainable neural network. *Energy Conversion and Management*, 226, 113487.
- Yadav, A. K., & Chandel, S. S. (2014). Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and Sustainable Energy Reviews*, 33, 772-781.
- Yadav, A. K., Malik, H., & Chandel, S. S. (2014). Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models. *Renewable and Sustainable Energy Reviews*, 31, 509-519.
- Yang, D., Kleissl, J., Gueymard, C. A., Pedro, H. T., & Coimbra, C. F. (2018). History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. *Solar Energy*, 168, 60-101.
- Zeng, P., Sun, X., & Farnham, D. J. (2020). Skillful statistical models to predict seasonal wind speed and solar radiation in a Yangtze River estuary case study. *Scientific Reports*, 10(1), 1-11.