

Akdeniz Bölgesine Ait Meteorolojik Veriler Kullanılarak Yapay Sinir Ağları Yardımıyla Güneş Enerjisinin Tahmini

Muhittin Şahan^{1,*} Yüksel Okur¹

Osmaniye Korkut Ata Üniversitesi, Fen Edebiyat Fakültesi, Fizik Bölümü, 80000, Osmaniye, Türkiye
*Yazışılan yazar e-posta: muhittinsahan@osmaniye.edu.tr

Alınış: 07 Nisan 2016, Kabul: 19 Nisan 2016

Özet: Akdeniz Bölgesinden seçilen on dört yerleşke yerine ait aylık ortalama toplam güneş ışınım şiddetini tahmin etmek amacıyla yapay sinir ağı (YSA) modeli kullanılmıştır. Geliştirilen YSA'nın mimari yapısı logaritmik sigmoid transfer fonksiyonu kullanan on iki nöronlu bir gizli katmandan ve lineer transfer fonksiyonu kullanan bir çıktı katmandan oluşan ileri beslemeli geri yayımlı bir modeldir. YSA modelinde Levenberg Marquand geri yayılım eğitim algoritması kullanılmıştır. 1993-2010 yılları arasındaki meteorolojik ve coğrafik veriler (aylık ortalama güneş ışınımı, ortalama hava sıcaklığı, minimum toprak üstü sıcaklığı, 5cm'deki toprak sıcaklığı, bağıl nem, bulutluluk, hava basıncı, güneşlenme süresi, istasyon, ay, enlem, boylam ve yükseklik) Meteoroloji Genel Müdürlüğü'nden alınmıştır. Tahmin edilen ve ölçülen aylık ortalama toplam güneş ışınımı istatistik yöntemler kullanılarak karşılaştırılmıştır. R^2 , RMSE, MAPE, MSE, MABE ve WI istatistiksel değerleri sırasıyla %94, 1.562 MJ/m², %7.9, 2.441MJ/m², 1.072 MJ/m² ve 0.983MJ/m² olarak bulunmuştur. Sonuçlar, tahmin edilen ve ölçülen toplam güneş ışınım şiddetinin değerleri arasında oldukça uyumlu olduğunu göstermiştir. Geliştirilen YSA modelinin diğer yerleşim yerleri ve farklı durumlar için tahmin etmede kullanılabileceğini önermekteyiz.

Anahtar kelimeler: Güneş ışınım şiddeti, yapay sinir ağları, meteorolojik veriler, modelleme, tahmin metodu

Estimation of the Solar Radiation Using Some Meteorological Data for the Mediterranean Region with the Artificial Neural Network

Abstract: An artificial neural network (ANN) model was used to estimate monthly average global solar radiation on a horizontal surface for selected 14 locations in Mediterranean region. The ANN architecture designed is a feed-forward back-propagation model with one hidden layer containing twelve neurons with logarithmic sigmoid as the transfer function and one output layer utilized a linear transfer function. The training algorithm used in ANN model was the Levenberg Marquand back propagation algorithm. The data between 1993-2010 based on meteorological and geographical parameters (monthly mean global solar radiation, average air temperature, minimum soil surface temperature, soil temperature at depths of 5 cm, relative humidity, cloudiness, vapor pressure, and sunshine duration, station, month, latitude, longitude, and altitude) were taken from Turkish State Meteorological Service. Estimated and measured average global solar radiation were compared by using statistical methods. The R^2 , RMSE, MAPE, MSE, MABE, and WI values were found to be 94%, 1.562MJ/m², 7.9%, 2.441MJ/m², 1.072 MJ/m², and 0.983MJ/m², respectively. Results show good agreement between the estimated and measured values of global solar radiation. We suggest that the developed ANN model can be used to predict solar radiation another location and conditions.

Key words: Solar radiation, artificial neural network, meteorological data, modeling, estimation method

1. Giriş

Günümüzde ülkelerin yüz yüze oldukları en büyük sorun sürekli artan enerji ihtiyacını karşılayabilmek için çevreye fazla zarar vermeden, yeterli ekonomik büyümeyi

sağlayacak düzeyde enerji üretecek yeni kaynaklar bulmaktır. Bu kaynakların başında gelen güneş enerjisi, son yıllarda üzerinde daha çok çalışılması gereken bir konu olmuştur. Dünya atmosferinin dışına gelen güneş ışınımının değeri, atmosferin dışında ışınım değeri yaklaşık 1367 W/m^2 'dir [1,2,3,4]. Yılda toplam $3 \times 10^{21} \text{ J}$ kadarlık güneş enerjisi yeryüzüne ulaşmakta ve bu enerji miktarı insanlığın ihtiyaç duyduğu enerjinin milyarlarca katıdır [5]. Güneşten dünyamıza ulaşan enerji bölgelere göre değişmektedir ($0-1020 \text{ W/m}^2$).

Yenilenebilir Enerji Genel Müdürlüğü (YEGM) tarafından yapılan çalışmaya göre, Türkiye'nin ortalama günlük güneşlenme süresi toplam 7.2 saat ve ortalama günlük toplamışınım şiddeti 3.6 kWh/m^2 'dir. Türkiye güneş kuşağı olarak adlandırılan bölgede bulunmakta olup güneş enerjisi açısından zengin bir ülkedir ve güneş enerjisi potansiyeli 380 milyar kWh/yıl olarak hesaplanmıştır. Yeryüzünde belirli bir bölgeye gelen güneş enerjisi potansiyelinin belirlenmesi çok önemlidir. Belirli bir bölgedeki güneş enerjisi potansiyelini belirlemek amacıyla yapılan meteorolojik gözlemler, nitelikli insan gücü ve önemli ekonomik yatırımlar gerektirmektedir. Gözlem cihazlarının pahalı olması, cihazların bakım ve kalibrasyonlarının gerekli şekilde ve sıklıkta yapılamaması, verilerin iletiminde ve saklanmasında yaşanan problemler, deneyimli ve yeterli eleman olmaması gibi problemler, gözlem istasyonlarının kurulmasını ve işletimini olumsuz yönde etkilemektedir. Güneş enerjisi uygulamaları için yürütülen alan çalışmaları oldukça pahalı ve zaman alıcı olmasının yanı sıra sistemden kaynaklanan başarısızlıkların ve kötü hava şartlarının neden olabileceği gecikmelerden de etkilenebilir [6]. Yaşanan bu sıkıntılar, güneş enerjisi potansiyelini belirlemek için güneş radyasyonu tahmin modellemesi çalışmalarını gündeme getirmiştir. Yatay düzleme gelen küresel güneş enerjisi miktarını tahmin etmek amacıyla ampirik veya teorik pek çok model geliştirilmiştir. Literatürde güneş radyasyonu tahmin etmek için bağıl nem, bulutluluk, buhar basıncı, güneşlenme süresi, toprak sıcaklığı gibi çeşitli iklim parametreleri kullanarak oluşturulan yapay sinir ağı (YSA) modellerinin diğer ampirik regresyon modellerinden daha üstün olduğu görülmüştür [2,3,7,8,9,10].

2. Materyal ve Metot

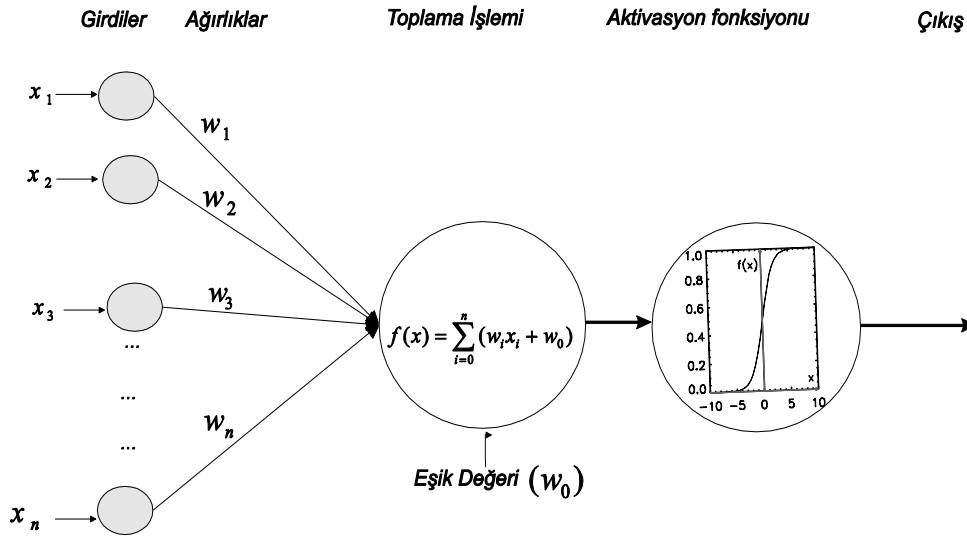
Bu çalışmada, Akdeniz Bölgesi'nden seçilen bazı yerleşim yerlerindeki aylık ortalama güneş ışınım şiddetini tahmin etmek için MGM'den (Meteoroloji Genel Müdürlüğü) uzun yıllara (1993-2010) ait meteorolojik ve coğrafik veriler alınmıştır. Meteorolojik veriler ortalama sıcaklık, bağıl nem, bulutluluk, buhar basıncı, güneşlenme süresi, toprak üstü minimum sıcaklık, 5 cm'de toprak altı sıcaklığı, ve günlük toplam global güneşlenme şiddeti verileri ile coğrafik veriler enlem, boylam, yükseklik, ay ve yıl olmak üzere toplam on üç farklı parametreden oluşmaktadır. Bu çalışmada kullanılan on dört merkezin adı ve bu merkezlerin enlem, boylam ve rakım bilgileri Tablo 1'de verilmiştir.

YSA insan beyninin çalışma ilkesinden esinlenilerek beyindeki sinir hücrelerinin yapay olarak taklit edilmesi ve karmaşık problemleri çözmek amacıyla bilgisayar sistemlerine uygulanması sonucu ortaya çıkmış bir veri işleme tekniğidir. YSA kendisine verilen örnekleri kullanarak öğrenmekte, veriler ve genel olarak veriler arasındaki ilişkilerin çok karmaşık ve doğrusal olmadığı durumlarda kullanılmaktadır [11,12,13,14,15].

YSA'nın temel yapı birimini oluşturan yapay sinir hücrelerinin (nöronların) genel yapısı; girdiler (x_i), ağırlıklar (w_i), toplam fonksiyonu (birleştirme fonksiyonu), aktivasyon (transfer) fonksiyonu ve çıktı olmak üzere beş ana kısımdan oluşmaktadır (Şekil 1). Girdilerin her biri ağırlık ile çarpılarak elde edilen ürünler basitçe eşik değeri ile toplanır ve sonucu oluşturmak için aktivasyon fonksiyonu ile işlem yapılır ve çıkışı alınır. Bir yapay sinir hücresinin öğrenme yeteneği, seçilen öğrenme algoritması içerisinde ağırlıkların uygun bir şekilde ayarlanmasına bağlıdır [12,16].

Tablo 1. Akdeniz Bölgesinden seçilen merkezlere ait enlem, boylam ve rakım bilgileri (<http://www.mgm.gov.tr>)

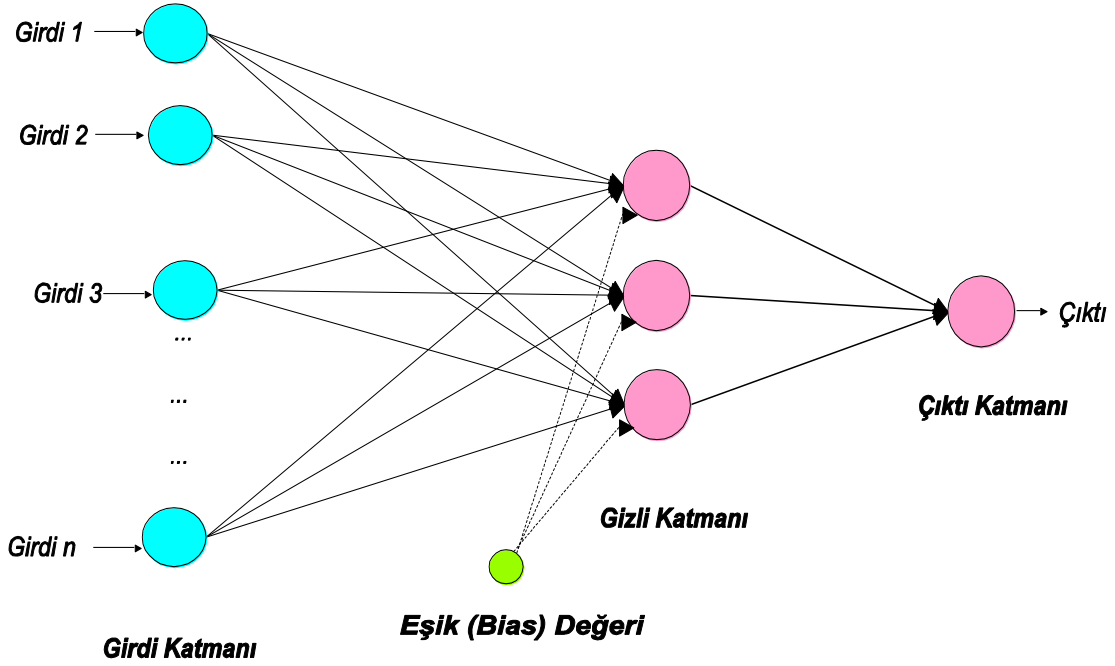
Merkez	Enlem (° K)	Boylam (° D)	Rakım (m)
Adana	37.00	35.19	27
Kozan	37.26	35.49	115
Karataş	36.34	35.23	22
Burdur	37.43	30.17	957
Antalya	36.53	30.40	47
K.Maraş	37.35	36.55	572
Elbistan	38.12	37.12	1137
Göksun	38.01	36.29	1344
Isparta	37.47	30.34	997
Antakya	36.15	36.08	100
İskenderun	36.35	36.10	2
Mersin	36.48	34.38	3
Anamur	36.50	32.50	5
Silifke	36.23	33.56	15



Şekil 1. Yapay sinir hücresinin genel giriş-çıkış yapısı (matematiksel mimarisi) [12]

YSA modelleri yapılarına, katmanlarına ve öğrenme algoritmalarına göre sınıflandırılmaktadır. Ağın yapısını ağı meydana getiren nöronlar arasındaki bağlantıların yapısı belirler [17]. En basit hali ile çok katmanlı ileri beslemeli bir YSA'nın mimari yapısı Şekil 2'de verilmiştir. Şekil 2'de görüldüğü gibi çok katmanlı ileri beslemeli bir YSA'nın mimari yapısı girdi (input) (Girdi 1, Girdi 2...), gizli

(hidden) ve çıktı (output) olmak üzere üç katmandan ve her bir katman nöron ya da işlem elemanı olarak adlandırılan bir ya da daha fazla sayıda basit yapay sinir hücresinden oluşmaktadır.



Şekil 2. İleri beslemeli bir YSA mimarisinin genel yapısı[12]

Dışarıdan gelen verilerin ilk kez YSA'ya alınmasını ve gizli (ara) katmana aktarılmasını sağlayan girdi katmanında dış dünyadan gelecek giriş sayısı kadar nöron bulunmaktadır [18]. Girdi katmanından gelen bilgiler belirli kurullarla işlenerek çıktı katmanına gönderilirler. Ağın temel işlevini gören katman gizli katmandır. Gizli katman sayısı amaca yönelik olarak ağdan ağa değişmektedir [18,19]. Çıktı katmandaki işlem elemanları ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için üretmesi gereken çıktıyı üretirler. Çıktı katmanındaki nöron sayısı, ağa sunulan her verinin çıkış sayısı kadardır. Bu katmandan elde edilen değerler YSA'nın söz konusu problem için çıkış değerleridir [19]. YSA kullanılarak herhangi bir problemin modellenmesindeki en önemli nokta, çözümlenmesi istenilen probleme en iyi çözümü verecek en uygun YSA mimarisini, yani YSA'daki gizli katman sayısını ve gizli katman/katmanlardaki işlem elemanı sayısının/sayılarının belirlenmesidir [20].

Bu çalışmada, YSA parametreleri (eğitim fonksiyonu, gizli transfer fonksiyonu, gizli katmandaki nöron sayıları, çıktı fonksiyonu gibi) değiştirilerek pek çok model denenmiş ve en uygun model bulunmaya çalışılmıştır. En uygun YSA'nın mimari yapısı logaritmik sigmoid (logsig) transfer fonksiyon kullanan 12 nöronlu bir gizli katmandan ve lineer (purelin) transfer fonksiyonu kullanan bir çıktı katmandan oluşan ileri beslemeli geri yayımlı YSA (FFBPANN) (feed-forward back propagation network: newff) modeli olduğuna karar verilmiş ve veriler buna göre eğitilmiştir. YSA modelinde Levenberg Marquand geri yayılım algoritması (*trainlm*) eğitim algoritması kullanılmıştır.

Yapılan hesaplamaların diğer araştırmacılar tarafından da anlaşılabilmesi ve benzer yolla elde edilmiş farklı bilgilerle karşılaştırılabilmesi önemlidir. Bu nedenle elde edilen verilerin belli kurallara göre, bütün ve dağılımlar halinde özetlenerek sunulması zorunluluğunu getirmiştir. Bu amaçla değişik istatistik yöntemler geliştirilmiş ve pek çok istatistik çalışmalarında değişkenler arasındaki ilişkiyi incelemek bilimin uğraşlarından birisi olagelmıştır [21]. Ölçülen güneş radyasyonu ile modellerden tahmin edilen değerlerinin performansını değerlendirmek amacıyla birçok istatistiksel test yöntemi bulunmaktadır. Literatürde YSA belirlemede en çok kabul gören model performans kriterleri Eşitlik 1’de verildiği gibi sırasıyla Korelasyon Katsayısı (R^2), Hata Kareleri Ortalamasının Karekökü (RMSE), Mutlak Hata Oranları Ortalaması (MAPE), Hata Kareleri Ortalaması (MSE), Mutlak Ortalama Bias Hata (MABE) ve Willmott indeksi (WI) değerleridir [22,23,24].

$$\begin{aligned}
 R &= \frac{\sum_{i=1}^n (x_i - \bar{x}_i)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}_i)^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y}_i)^2}}, & RMSE &= \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \\
 MAPE &= \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{x_i} \right| \times 100, & MSE &= \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \\
 MABE &= \frac{1}{n} \sum_{i=1}^n |x_i - y_i|, & WI &= 1 - \left[\frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (|y_i - \bar{x}_i| + |x_i - \bar{x}_i|)} \right]
 \end{aligned} \tag{1}$$

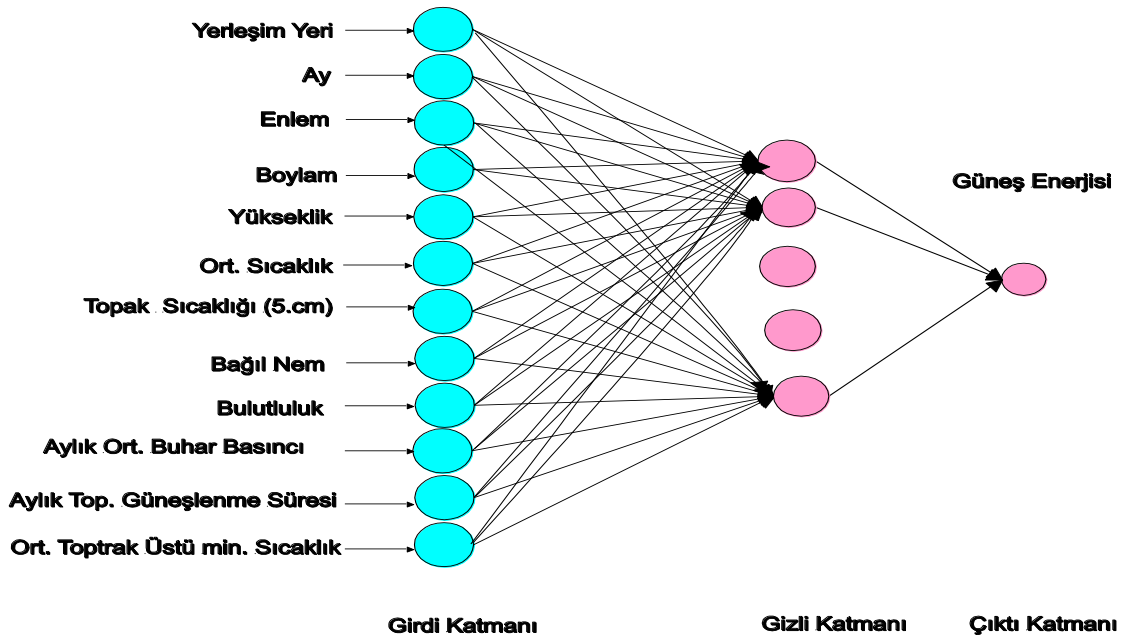
Burada, y_i ve x_i parametreleri sırasıyla tahmin edilen ve ölçülen güneş ışınım değerlerini göstermektedir. R^2 değeri 0 ile 1 arasında değişmekte ve bu değer 1’e yaklaşması modelden hesaplanan ve ölçülen güneş ışınım şiddeti değerleri arasındaki bağımlılığın kuvvetli olduğu anlamına gelmektedir. R^2 değeri 1’e ne kadar yakınsa model o kadar hassas demektir [25]. YAS’nın belirlenmesinde R^2 ’nin en yüksek ve RMSE, MAPE, MSE, MABE ve WI’nin en düşük olduğu değerler göz önüne alınmıştır.

3. Bulgular

Bu çalışmada, Akdeniz Bölgesi’nden farklı coğrafi özellik ve iklim koşullarına sahip on dört yerleşim yeri için yatay düzleme gelen aylık ortalama güneş ışınım şiddetini tahmin etmek amacıyla YSA modeli geliştirilmiştir. YSA modelinin test edilmesi ve modelin eğitilmesi amacıyla MGM’den alınan on dört yerleşim yerine ait on sekiz yıllık (1993–2010) meteorolojik veriler kullanılmıştır. Seçilen on dört yerleşim yerinin isimleri Doğu Akdeniz’den Batı Akdeniz’e doğru sırasıyla Kahramanmaraş, Elbistan, Göksun, Adana, Kozan, Karataş, Antakya, İskenderun, Mersin, Anamur, Silifke, Burdur, Isparta ve Antalya’dır (Tablo1). MGM’den on dört yerleşim yerine ait alınan on sekiz yıllık meteorolojik ve coğrafi veriler sırasıyla yerleşim yeri, enlem, boylam, yükseklik, ay, yıl, bulutluluk, buhar basıncı, güneşlenme süresi, hava sıcaklığı, toprak üstü minimum sıcaklık, toprak altı sıcaklık (5cm), bağıl nem ve toplam güneşlenme şiddeti değerlerinin aylık ortalamalarından oluşmaktadır. Alınan meteorolojik ve coğrafi veriler seçilen on dört yerleşim yeri için yatay yüzeye gelen aylık ortalama toplam güneş ışınım şiddetini tahmin etmek amacıyla YSA modelini kullanan bir model geliştirilmiştir.

Bu çalışmada, Neural Network Toolbox (nntool) kullanılarak MATLAB ortamında çalışan bir bilgisayar programı geliştirilmiştir. Tablo 1’de verilen yerleşim yerlerine ait aylık ortalama toplam güneş ışınım şiddet verilerini tahmin etmek için YSA modeli kullanılmıştır. Başlangıçta, verilerin ortalama % 80’i ağı eğitmek amacıyla ağda girdi “input” olarak, kalan %20’si ise geliştirilen modeli test etmek amacıyla kullanılmıştır. YSA modelinde girdi olarak on iki tane coğrafik ve meteorolojik parametre kullanılarak sadece bir çıktısı (toplam global güneşlenme şiddeti) tahmin edilmiştir.

Çalışmada kullanılan on iki girdi katman, gizli katman ve bir çıktı katmanından oluşan YSA’nın mimari yapısı Şekil 4’te verilmiştir. Giriş katmanında on iki parametreye karşılık gelen on iki nöron, çıkış katmanında aylık ortalama güneş ışınımına karşılık gelen sadece bir nöron bulunmaktadır.



Şekil 3. Kullanılan YSA mimarisi[21]

Oluşturulan veri setlerinin eğitilmesi amacıyla “trainlm”, “trainbfg”, “trainscg”, “traincgb”, “trainoss”, “traingdx” ve “traincgp” gibi farklı eğitim algoritmaları, “learngdm”, “learngd” gibi farklı öğrenme fonksiyonları ve “tansig”, “purelin” ve “logsig” gibi farklı transfer fonksiyonları kullanarak YSA dizayn edilmiştir. Eğitim algoritması belirlenirken en büyük R^2 değerine ve en düşük RMSE, MSE, MABE ve MAPE değerlerine bakılmıştır (Tablo 2). Buna göre, R^2 değerinin en büyük değeri(%94) ve RMSE (1.542 MJ/m²), MSE (2.378 MJ/m²), MABE (1.084 MJ/m²), MAPE (%8) değerlerinin en düşük olduğu ileri beslemeli geri yayımlı “trainlm” eğitim algoritması kullanılmıştır. Ayrıca eğitim algoritmasına karar verirken, mümkün olan en kısa sürede eğitimi en iyi iterasyonla tamamlamasına bakılarak da YSA eğitim algoritmasına karar verilmiştir. Buna göre YSA mimari yapısının kırk dört iterasyonluk (epoch) eğitimi iki saniyede tamamlayan Levenberg Marquand geri yayılım “trainlm” eğitim algoritma ile diğer algoritmalarından daha hızlı olduğunu göstermektedir.

İleri beslemeli geri yayımlı “*trainlm*” eğitim algoritması kullanılarak gizli katmandaki nöron sayıları beş ile elli arasında aşamalı olarak değiştirilerek farklı model oluşturulmuştur. Oluşturulan modellerden yirmi beş tanesi Tablo 3’te verilmiştir.

Tablo 3’te verilen algoritmalarından R^2 değerinin en büyük (%94) ve RMSE (1.562 MJ/m²), MSE (2.441 MJ/m²), MABE (1.072 MJ/m²), MAPE (%79) ve WI (0.983 MJ/m²) gibi diğer istatistiksel değerlerin en düşük olduğu model seçilmiştir. Böylece en uygun model olarak on iki gizli nörona sahip olan yedi numaralı model olduğu görülmüştür. Buna göre YSA modeli on iki tane girdi katmanından, gizli katman da on iki tane nöron ve bir tane çıktı katmanından (12-12-1) oluşmaktadır. Gizli katmanda “*logsig*” transfer fonksiyonu ve çıktı katmanında da “*purelin*” transfer fonksiyonu kullanılmıştır. Bu modelin regresyon eşitliğinin yaklaşık olarak $y = 0.992995x + 0.519199$ ve R^2 değerinin de yaklaşık olarak %94 olduğu görülmektedir.

Tablo 2. Güneş enerjisi verilerinin tahmin etmek için eğitim algoritmasının belirlenmesinde kullanılan algoritmalar ve istatistiksel değerler

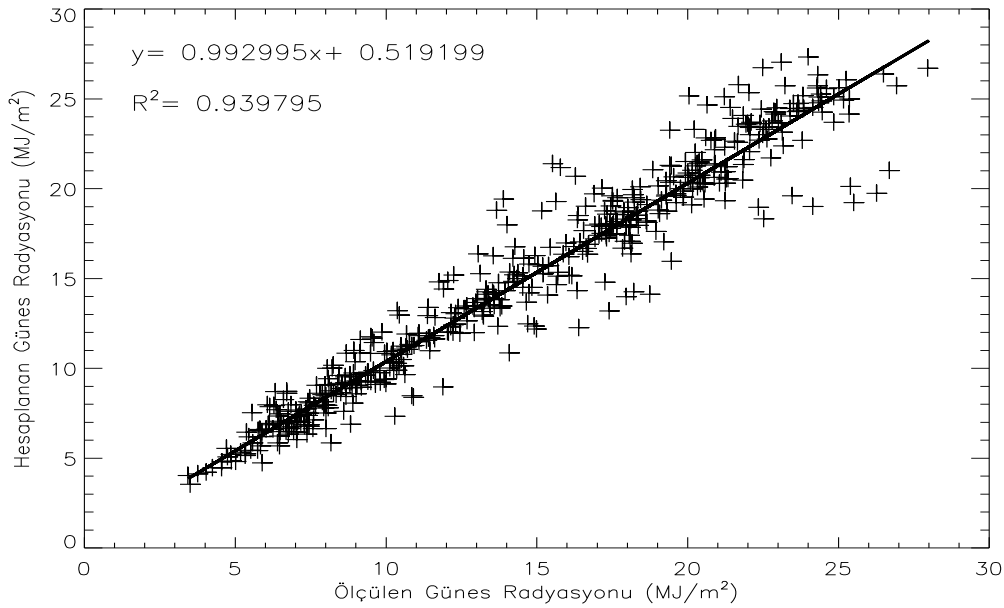
Algoritma	İterasyon (epoch)	Süre (s)	R^2 (%)	RMSE (MJ/m ²)	MSE (MJ/m ²)	MABE		MAPE	
						(M	(%
trainlm	44	2	0.940	1.542	2.378	1.084	0.080		
trainbfg	82	8	0.931	1.637	2.678	1.258	0.094		
traingdx	92	7	0.842	2.433	5.918	1.872	0.154		
trainoss	112	17	0.873	2.185	4.775	1.693	0.135		
traincgp	41	9	0.798	2.803	7.856	2.149	0.170		
traincgb	78	14	0.892	2.141	4.583	1.657	0.131		
trainsicg	75	9	0.896	2.046	4.185	1.560	0.121		

Tablo 3’te yedi numaralı YSA modelinden hesaplanan aylık ortalama güneş radyasyonu ile MGM’den alınan aylık ortalama güneş radyasyonu arasındaki ilişkiye bakılmış ve elde edilen grafik Şekil 4’te verilmiştir. Şekil 4’te yatay eksen ölçülen toplam güneş radyasyonunun ve dikey eksen ise YSA modeli ile hesaplanan toplam güneş radyasyonunun göstermektedir. Şekil 4’te verilen “+” sembolleri test edilen beş yüz dört tane veriyi temsil etmektedir. Elde edilen regresyon eğrisi denklemi ve R^2 değeri grafiğin sol üst köşesinde verilmiştir.

Tablo 3’te verilen yedi numaralı YSA modeli kullanılarak her bir yerleşim yerine ait tahmin edilen toplam enerji değeri ile ölçülen toplam enerji değerinin model performans kriterleri kullanılarak karşılaştırma yapılmıştır. Yapılan karşılaştırmalarda belirlenen model kullanılarak tahmin edilen güneş enerjisi değerlerinin ölçülen değerlere çok yakın olduğu görülmüştür.

Tablo 3. Farklı eğitim algoritmaları ve mimari yapıları kullanılarak geliştirilen YSA modelleri

NO	Eğitim Fonksiyonu	Gizli Transfer Fonksiyonu	Çıktı Fonksiyonu	Gizli Katmandaki Nöron Sayıları	Mimari Yapı	R ² (%)	MSE (MJ/m ²)	MAPE (%)	MSE (MJ/m ²)	MABE (MJ/m ²)	WI (MJ/m ²)
1	trainlm	tansig	purelin	5	12-5-1	0.926	1.717	0.092	2.948	1.225	0.980
2	trainlm	logsig	purelin	22	12-22-1	0.930	1.647	0.086	2.711	1.158	0.981
3	trainlm	logsig	tansig	5	12-5-1	0.926	1.699	0.089	2.886	1.175	0.980
4	trainlm	tansig	purelin	5	12-5-1	0.925	1.719	0.089	2.956	1.203	0.979
5	trainlm	tansig	tansig	5	12-5-1	0.931	1.714	0.086	2.936	1.170	0.980
6	trainlm	logsig	purelin	10	12-10-1	0.935	1.599	0.081	2.557	1.104	0.982
7	trainlm	logsig	purelin	12	12-12-1	0.940	1.562	0.079	2.441	1.072	0.983
8	trainlm	logsig	purelin	22	12-22-1	0.930	1.647	0.086	2.711	1.158	0.981
9	trainlm	logsig	purelin	18	12-18-1	0.930	1.647	0.086	2.711	1.158	0.981
10	trainlm	logsig	purelin	18	12-18-1	0.930	1.647	0.086	2.711	1.158	0.981
11	trainlm	logsig	purelin	20	12-20-1	0.926	1.677	0.090	2.811	1.173	0.980
12	trainlm	tansig	tansig	20	12-20-1	0.921	1.777	0.097	3.157	1.265	0.978
13	trainlm	tansig	purelin	22	12-22-1	0.934	1.613	0.090	2.603	1.150	0.982
14	trainlm	logsig	purelin	25	12-25-1	0.928	1.720	0.081	2.959	1.106	0.980
15	trainlm	tansig	purelin	25	12-25-1	0.933	1.685	0.087	2.840	1.163	0.981
16	trainlm	tansig	tansig	25	12-25-1	0.925	1.701	0.084	2.894	1.122	0.980
17	trainlm	logsig	purelin	30	12-30-1	0.934	1.659	0.084	2.753	1.132	0.981
18	trainlm	tansig	purelin	30	12-30-1	0.928	1.690	0.084	2.856	1.107	0.980
19	trainlm	logsig	tansig	32	12-32-1	0.928	1.681	0.080	2.827	1.092	0.980
20	trainlm	tansig	purelin	35	12-35-1	0.926	1.752	0.085	3.070	1.180	0.979
21	trainlm	logsig	purelin	35	12-35-1	0.935	1.575	0.079	2.481	1.058	0.983
22	trainlm	tansig	tansig	35	12-35-1	0.926	1.723	0.085	2.970	1.125	0.980
24	trainlm	tansig	purelin	40	12-40-1	0.931	1.658	0.086	2.748	1.127	0.981
25	trainlm	tansig	tansig	50	12-50-1	0.931	1.669	0.085	2.785	1.117	0.981



Şekil 4. Yedi numaralı YSA modelinden seçilen yerleşim yerleri için ölçülen ve tahmin edilen yıllık ortalama güneş enerjisi arasındaki ilişki ve geçirilen regresyon eğrisi

Yerleşim yerleri bazında istatistiksel analiz yöntemleri kullanılarak yapılan istatistiksel karşılaştırmalar Tablo 4’te verilmiştir. Tablo 4 incelendiğinde R^2 değerleri %89 – %99 arasında değiştiğinden buna bağlı olarak diğer istatistik değerlerinin de düşük olduğundan geliştirilen modelin oldukça iyi olduğu görülmektedir.

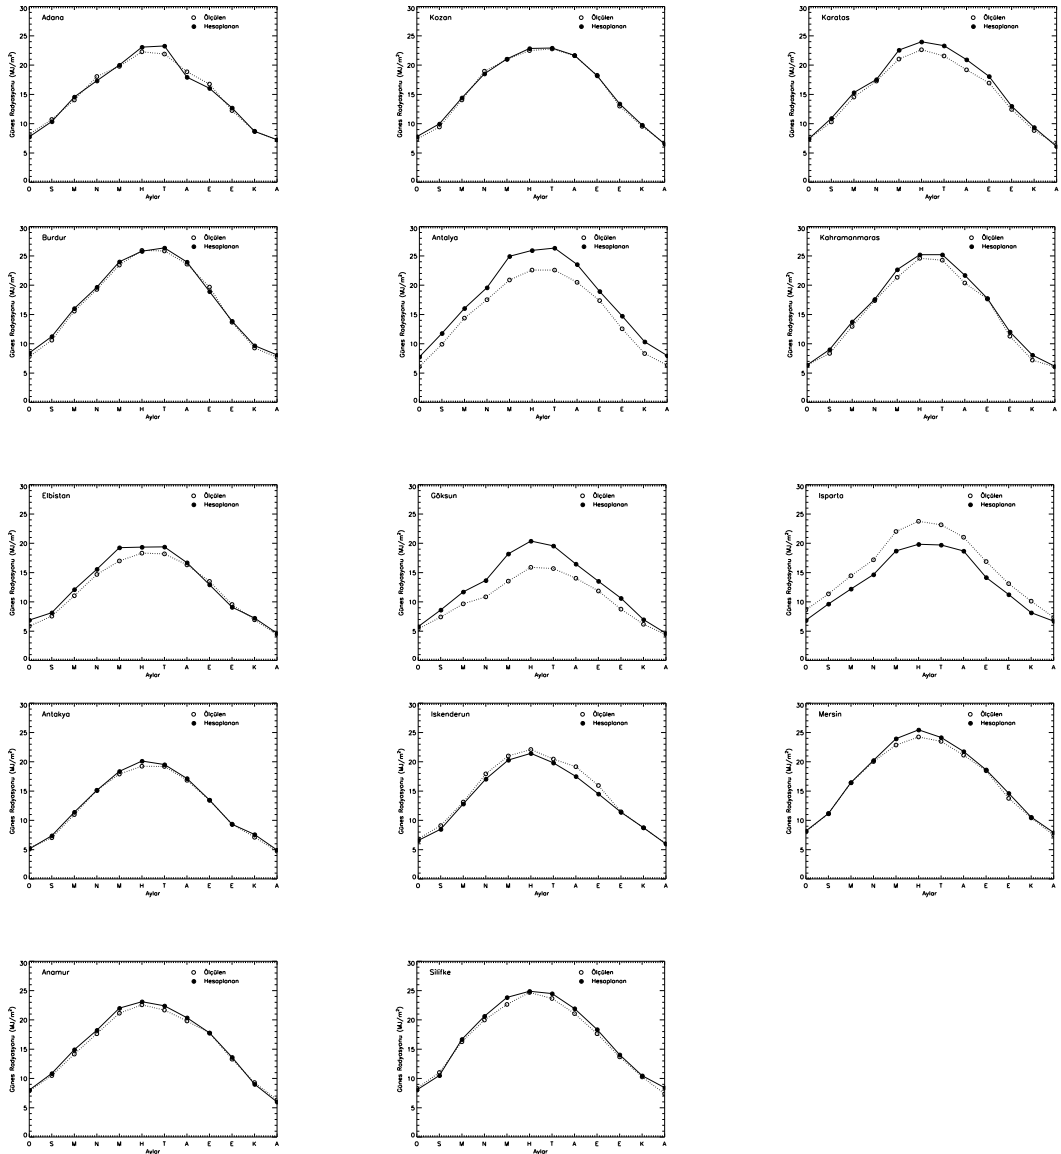
Tablo 3’te verilen yedi numaralı YSA modeli kullanılarak hesaplanan on dört yerleşim yeri için aylık ortalama toplam güneş enerjilerin tahmin edilen ve ölçülen değerleri ile ayrı ayrı karşılaştırmaları yapılmıştır. Yapılan çalışma sonucunda her yerleşim yeri için hesaplanan ve ölçülen güneş enerjisi değerlerin üç yıllık verilerin aylık ortalamaları alınarak elde edilen aylık ortalama değişimlerine bakılmış ve sonuçlar Şekil 5’te verilmiştir. Şekil 5’teki grafiklerde ölçülen değerler içi boş (o) çemberler ile YSA ile hesaplanan veriler içi dolu çemberler ile (●) gösterilmiştir. Şekil 5’te tüm merkezler için hesaplanan güneş enerjisi değerlerinin ölçülen değerlerle uyumlu olduğu görülmüştür.

Tablo 4. Yerleşim yerlerine ait test edilen verilerin lineer ve çoklu lineer regresyon analizi yöntemleri ve istatistiksel analiz sonuçları

	R^2 (%)	RMSE (MJ/m ²)	MAPE (%)	MSE (MJ/m ²)	MABE (MJ/m ²)	WI (%)
Adana	0.926	1.519	0.079	2.309	1.171	0.980
Kozan	0.995	0.438	0.029	0.192	0.357	0.999
Karata	0.992	1.132	0.062	1.282	0.964	0.991
Burdur	0.981	0.992	0.050	0.984	0.776	0.995
Antalya	0.983	2.628	0.179	6.908	2.408	0.958
K.Maraş	0.994	0.842	0.057	0.710	0.717	0.996
Elbistan	0.969	1.172	0.081	1.374	0.921	0.987
Göksun	0.961	2.752	0.194	7.574	2.219	0.913
Isparta	0.898	3.164	0.151	10.011	2.516	0.918
Antakya	0.990	0.614	0.046	0.377	0.498	0.997
İskenderun	0.986	0.925	0.056	0.856	0.740	0.993
Mersin	0.996	0.666	0.032	0.443	0.524	0.997
Anamur	0.992	0.693	0.039	0.480	0.557	0.996
Silifke	0.989	0.818	0.045	0.669	0.645	0.995

4. Sonuç ve Tartışma

Bu çalışmada, güneş enerjisinin tahmini için yapay sinir ağı temelli bir model geliştirilmiştir. Akdeniz Bölgesi’ndeki (Türkiye) on dört meteoroloji istasyonlarından alınan on sekiz yıllık (1993-2010) meteorolojik veriler MGM’den alınmıştır. YSA modelinden hesaplanan değerler ile MGM’den alınan ölçülmüş gerçek değerler istatistiksel yöntemler kullanılarak karşılaştırılmıştır. Bu sonuçlar, YSA modeli ile tahmin edilen ve ölçülen aylık ortalama toplam güneş ışınımı değerlerinin oldukça uyumlu olduğunu göstermiştir. YSA modelinin meteorolojik ve coğrafi parametreler olan herhangi bir bölge için toplam güneş ışınımını tahmininde kullanılabileceğini önermekteyiz.



Şekil 5. Akdeniz Bölgesi'nden seçilen on dört farklı yerleşim yeri için ölçülen ve YSA ile hesaplanan ortalama aylık toplam güneş ışınım değerleri

Teşekkür

Bu çalışma Osmaniye Korkut Ata Üniversitesi Bilimsel Araştırma Projeleri (BAP) Destekleme Programı tarafından **OKÜBAP-2014-PT3-035** proje numarası ile desteklenmiştir. Meteoroloji İşleri Genel Müdürlüğüne veri temini için teşekkür ederiz.

Kaynaklar

- [1] Duncan C.H., Willson R.C., Kendall J. M., Harrison R.G., Hickey J.R., 1982. Latest rocket measurements of the solar constant, *Solar Energy*, 28: 385-387.
- [2] Iqbal M., 1983. An introduction to solar radiation, Academic Press Chap. 3.
- [3] Foukal P.V., 1990. Solar Astrophysics, *Wiley-Interscience*, New York.
- [4] Duffie J.A., Beckman W.A., 1991. Solar engineering of thermal processes, 2th Edition, *John Wiley and Sons Inc.*, New York.

- [5] Altın V., 2002. Yenilenebilir enerji kaynakları, *Bilim-Teknik Dergisi – Yeni Ufuklara Eki, TÜBİTAK*, 410: 2-23.
- [6] Elminir H.K., Areeed F.F. Elsayed T.S., 2005. Estimation of Solar radiation components incident on Helwan Site using neural networks, *Science Direct Solar Energy*, 79: 270–279.
- [7] Krishnaiah T., SrinivasaRao S., Madhumurthy K., Reddy K.S., 2007. Neural network approach for modeling global solar radiation, *Journal of Applied Sciences Research*, 3 (10): 1105-1111.
- [8] Mubiru J., Banda E.J.K.B., 2008. Estimation of monthly average daily global solar irradiation using artificial neural networks, *Science Direct Solar Energy*, 82: 181-187.
- [9] Alama S., Kaushik S.C., Garg S.N., 2006. Computation of beam solar radiation at normal incidence using artificial neural network, *Science Direct Renewable Energy*, 31: 1483-1491.
- [10] Fadare D.A., Irimisose I., Oni A.O., Falana A., 2010. Modeling of solar energy potential in Africa using an artificial neural network, *American Journal of Scientific and Industrial Research*, 1(2): 144-157.
- [11] Basheer I.A., Hajmeer M., 2000. Artificial neural networks: fundamentals, computing, design, and Application, *Journal of Microbiological Methods*, 43: 3-31.
- [12] Graupe D., 2007. Principles of artificial neural networks, (2nd Edition), advanced series on circuits and systems, 6, *World Scientific Publishing Co. Pte. Ltd.*
- [13] Singh K. P., Basant A., Malik A., Jain G., 2009. Artificial neural network modeling of the river water quality-A case study, *Ecological Modelling*, 220: 888-895.
- [14] Russel S., Norvig P., 2010. Artificial intelligence a modern approach, Third edition, *Prentice Hall, Englewood Cliffs, New Jersey.*
- [15] Krishnaiah T., SrinivasaRao S., Madhumurthy K. ve Reddy K.S., 2009. Neural network approach for modelling global solar radiation, *Journal of Applied Sciences Research*, 3(10): 1105-1111.
- [16] Elmas Ç., 2003. Yapay sinir ağları (kuram, mimari, eğitim, uygulama), *Seçkin Yayıncılık*, Ankara.
- [17] Bahadır İ., 2008. Bayes teoremi ve yapay sinir ağları modelleriyle borsa gelecek değer tahmini uygulaması, TOBB Ekonomi ve Teknoloji Üniversitesi, FBE-Yüksek Lisans Tezi, Ankara.
- [18] Suzuki K., 2011. Artificial Neural networks-methodological advances and biomedical applications, InTech, Janeza Trdine 9, Rijeka, Croatia.
- [19] Fırat M., Güngör M., 2002. Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi, *İMO Teknik Dergisi*, 3267-3282.
- [20] Hawley D.D., Johnson J.D., Raina D., 1990. Artificial neural systems: A New tool for financial decision making, *Financial Analysts Journal*, 46(6): 63-72.
- [21] Okur Y., 2016. Akdeniz bölgesine ait meteorolojik veriler kullanılarak yapay sinir ağları yardımıyla güneş enerjisinin tahmini, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Osmaniye Korkut Ata Üniversitesi, Osmaniye.
- [22] De L.A.S., 1998. Forecasting principles and applications, Irwin, *McGraw-Hill*, Singapore.
- [23] Zhang G., Hu M.Y., 1998. Neural network forecasting of the British pound/us dollar exchange rate, *Omega*, 26(4): 495-506.
- [24] Cho V.A., 2003. Comparison of three different approaches to tourist arrival forecasting, *Tourism Management*, 24: 323-330.
- [25] Kalogiou S.A., 2000. Applications of artificial neural networks for energy systems, *Applied Energy*, 67: 17-35.

Yüksel Okur e-posta: yokur80@gmail.com