

ARAŞTIRMA MAKALESİ / RESEARCH ARTICLE

GÜNEŞ ENERJİSİ POTANSİYELİNİN ÇOKLU LİNEER REGRESYON VE
YAPAY SİNİR AĞLARI İLE MODELLENMESİDurhan GABRALI¹¹İAÜ, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Programı, Yüksek Lisans Öğrencisi, İstanbul
gabralidurhan@gmail.com ORCID No: 0000-0002-4920-7876Zafer ASLAN²²İAÜ, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul
zaferaslan@aydin.edu.tr ORCID No: 0000-0001-7707-7370

GELİŞ TARİHİ/RECEIVED DATE: 08.08.2019 KABUL TARİHİ/ACCEPTED DATE: 27.08.2020

Özet

Son yıllarda fosil yakıt kaynaklarının tükenmeye başlaması ve çevresel kaygılar nedeniyle yenilenebilir enerji kaynaklarının mevcut enerji üretiminde kullanım payı giderek artmaktadır. En önemli yenilenebilir enerji kaynaklarından olan güneş enerjisi; temiz, sürdürülebilir ve çevre dostu enerji kaynağı olması nedeniyle öne çıkmaktadır. Bu nedenle mevcut güneş enerji sistemlerinin işletimi veya yeni sistemlerin kurulumu sırasında, ilgili bölgelerin güneş radyasyonu özelliklerinin bilinmesi ve tahmin edilmesi çok önemlidir. Bu çalışmada, İstanbul Büyükçekmece İlçesi Eskice Bölgesine ait 2016 yılı meteorolojik verileri (güneş radyasyonu, rüzgâr şiddeti, UV radyasyon indis, toprak üstü 5 cm sıcaklık, sıcaklık 2 m, rüzgâr yönü) kullanılarak güneş radyasyonu için ileriye yönelik kısa ve orta vadeli bir tahmin çalışması yapılmıştır. Modelleme için Çoklu Lineer Regresyon (ÇLR) ve esnek hesaplama yöntemlerinden biri olan Yapay Sinir Ağları (YSA) kullanılmıştır. Geliştirilen tüm modeller istatistiksel olarak karşılaştırılmıştır. Sonuçlar güneş radyasyonu tahmininde YSA modellerinin ÇLR modellerinden daha başarılı olduğunu göstermektedir. Mevsimsel olarak güneş radyasyonu için en başarılı tahmin Haziran ayında elde edilmiştir. Bu aşamada kullanılan YSA modeli ile güneş radyasyonu için R, nRMSE ve MAPE değerleri sırasıyla 0.912, %48.5, %28.21 olarak hesaplanmıştır. Bu verilere dayalı olarak seçilen inceleme bölgesinde ve Haziran ayında güneş enerji potansiyelinin yeter güvenilirlik ile tahmin edilebileceği vurgulanabilir.

Anahtar Kelimeler: Yapay Sinir Ağları, Güneş Enerjisi, Güneş Radyasyonu Tahmini, Kısa Vadeli Tahmin, Çoklu Lineer Regresyon

**MODELING OF SOLAR ENERGY POTENTIAL WITH MULTIPLE LINEER REGRESSION AND
ARTIFICIAL NEURAL NETWORKS****Abstract**

In recent years due to the depletion of fossil fuel resources and environmental concerns, the share of renewable energy resources in the current energy production show an increasing trend. Solar energy one of the most important renewable energy sources; is a clean, sustainable and environmentally friendly energy

source. Therefore it is very important to know and estimate the solar radiation properties of the respective regions during the operation of existing solar energy systems or the installation of new systems. In this study meteorological data of 2016 (solar radiation, wind intensity, UV radiation index, surface 5 cm temperature, temperature 2 m, wind direction) belonging to Eskice region of Büyükçekmece District of Istanbul were used for a estimation solar radiation short and medium term. Multiple Linear Regression (MLR), and Artificial Neural Networks (ANN) which is one of the soft computing methods were used for modeling. All models were compared statistically. The results show that ANN models are more successful than MLR models in solar radiation estimation. Seasonally the most successful forecast for solar radiation was obtained in June. With the ANN model used in this stage for solar radiation R, nRMSE and MAPE values were calculated as 0.912, %48.5 and %28.21 respectively. Based on these data, it can be emphasized that solar energy potential can be estimated with sufficient reliability in the selected region and in June.

Keywords: Artificial Neural Networks, Solar Energy, Solar Radiation Estimation, Short Term Forecast, Multiple Linear Regression

1. GİRİŞ

Günümüzde global enerji ihtiyacının büyük bölümü fosil yakıt kaynaklarından karşılanmaktadır. Birincil enerji tüketimi %80 civarında fosil yakıt kaynaklarından sağlanırken geri kalanı yenilenebilir enerji kaynaklarından elde edilmektedir (Yılmaz ve Öziç, 2018). Fosil kaynaklı yakıt rezervleri ise kullanıma bağlı olarak her geçen gün azalmakta ve sınırlı rezervler yüzünden gelecek yakın bir zamanda biteceği öngörülmektedir (Rahman ve diğerleri, 2014). Sınırlı sayıda rezerve sahip olmaları ve çevreye verdikleri zararlı etkilerden dolayı fosil enerji kaynaklarına alternatif olarak yenilenebilir enerji kaynakları önem kazanmaktadır. Gelecek yıllarda yenilenebilir enerji kaynaklarının toplam enerji üretimindeki payının artacağı öngörülmektedir. Yenilenebilir enerji kaynakları içerisinde güneş enerjisi en önemli kaynaklardan biridir. Güneş enerjisi için de güneş radyasyonu önemli bir parametredir.

Türkiye coğrafi konumu nedeniyle güneş enerji potansiyeli yüksek olan bir ülkedir. Türkiye'nin Güneş Enerjisi Potansiyeli Atlasına (GEPA) göre yıllık ortalama toplam güneş ışınımının en yüksek olduğu bölgeler Güneydoğu Anadolu ve Akdeniz bölgeleri olmakla beraber Türkiye'deki hemen hemen her bölgede güneş enerji sistemleri verimli bir şekilde kullanılabilir (Kılıç, 2015). Bu çalışmada Marmara Bölgesinde bulunan İstanbul ilindeki belirli bir bölgede geleneksel istatistiksel yöntemler ve YSA kullanarak değişik meteorolojik parametrelere bağlı olarak güneş radyasyonu için tahmin modellemesi yapılmıştır.

Bilim adamları ve araştırmacılar şimdiye kadar güneş radyasyonunun ileriye yönelik tahmini için birçok araştırma yapmışlardır. Yapılan literatür taraması bu konuda çok sayıda yöntemin kullanıldığını göstermektedir. Sun ve diğerleri (2018a) güneş radyasyonu tahmin yöntemlerini matematik ve istatistik tabanlı geleneksel yöntemler, sayısal hava tahmini ve makine öğrenmesi olmak üzere üç kategoriye ayırmışlardır. Matematik ve istatistik tabanlı geleneksel yöntemler şunları içerir; regresyon analizi, zaman serileri analizi, gri veya kara kutu teorisi, bulanık teori, dalgacık analizi ve Kalman filtresi. Sayısal hava tahmini performanslı bilgisayarların meteorolojik verileri kullanarak karmaşık denklemleri çözmesi ile gerçekleştirilir. Büyük veri madenciliğinin gelişmesiyle beraber makine öğrenmesi teknikleri günümüzde büyük ilgi görmektedir. Örneğin yapay sinir ağları, destek vektör makineleri (SVM) ve sezgisel akıllı optimizasyon algoritmaları güneş radyasyonu tahmininde yaygın olarak kullanılmaktadır. Esnek hesaplama yöntemlerini içeren

makine öğrenmesi tekniklerinin tahmin yöntemi olarak birçok araştırmacı tarafından kullanıldığı ve bazı yönlerden diğer yöntemlerden üstün olduğu yapılan literatür taramasında görülmüştür.

Erdil ve Arçaklıoğlu (2013) Türkiye’de farklı ölçüm istasyonlarından elde edilmiş boylam, rakım, ay, günlük minimum ve maksimum nem, ortalama güneşlenme süresi, günlük minimum ve maksimum sıcaklık ile basınç verilerini girdi olarak kullanan ve günlük güneş radyasyonunu tahmin eden yapay sinir ağı modeli kullanmışlardır. Test sonuçlarında R^2 değeri 0.997 ve ortalama yüzde hata 5.775 olarak bulunmuştur. Elde edilen sonuçlar tahmini ve ölçülen değerler arasındaki farkın çok düşük olduğunu göstermektedir.

Long ve diğerleri (2014) çiy sıcaklığı, güneşlenme süresi, rüzgâr hızı, güneş radyasyonu, üretilen güç gibi parametrelere bağlı olarak günlük güneş enerjisi tahminini YSA dahil dört farklı yöntemle gerçekleştirmişlerdir. Tahminde daha etkili olabilecek parametreleri seçmek için korelasyona dayalı parametre seçim prosedürü uygulanarak önemli parametreler modellerde giriş olarak seçilmiştir. YSA sonuçlarında R^2 değeri 0.909, RMSE değeri 59.57, MAPE %11.87 olarak bulunmuştur.

Bou-Rabee ve diğerleri (2017) Kuveyt’te beş farklı bölgeden elde edilen verileri kullanarak günlük ortalama güneş radyasyonunu tahmin etmek için YSA modelleri kullanmışlardır. 2007-2010 arası verilerle eğitilen model, 2011 verileri ile test edilmiştir. Geliştirilen üç farklı YSA modeli içerinden Levenberg-Marquardt algoritmasını kullanan model %85.6 MAPE değeri ile en başarılı sonucu vermiştir.

Fan ve diğerleri (2019) küresel güneş radyasyonu tahmininde kullanılan ampirik ve makine öğrenmesi yöntemlerini kapsamlı bir literatür taraması yaparak özetlemişlerdir. Ayrıca Çin’in farklı iklim bölgelerinde küresel güneş ışıması tahmininde 12 ampirik ve 12 makine öğrenmesi yöntemi kullanarak performanslarını karşılaştırmışlardır. Sonuçlar, makine öğrenmesi modellerinin (RMSE: 2.055-2.751 $\text{MJm}^{-2} \text{d}^{-1}$; R^2 : 0.839-0.936) genellikle ampirik modellerden (RMSE: 2.118–3.540 $\text{MJm}^{-2} \text{d}^{-1}$; R^2 : 0.834-0.935) daha iyi performans gösterdiğini ortaya koymaktadır. Tahmin doğruluğu ve hesaplama maliyetleri dikkate alındığında, çalışmada ANFIS şiddetle tavsiye edilmektedir.

Ghofrani ve diğerleri (2019) örüntü tanıma ve makine öğrenme tekniklerinin güneş ışıması tahmini için kullanıldığını gösteren kapsamlı bir literatür taraması yapmışlardır. Bu araştırmanın sonuçları, veri kümeleme veya sınıflandırma ile düzensiz olan güneş ışıması zaman serilerinin düzensiz kalıplarının tanımlanmasının, sinir ağları için daha iyi bir eğitim sağladığını ve tahmin doğruluğunu arttırdığını göstermektedir. Bununla birlikte, çoklu örüntü tanıma ve makine öğrenme tekniklerini kullanan hibrit tahmin yöntemlerinin hesaplama karmaşıklıkları, bunları çevrimiçi tahminler veya çok kısa vadeli tahminler için yetersiz kılmaktadır.

2. ÇALIŞMA BÖLGESİ VE VERİLER

Bu çalışmada Şekil 1’deki haritada konumu gösterilen İstanbul İli Büyükçekmece İçesinde bulunan Tarım ve Orman Bakanlığına bağlı Tarım Bilgi Sistemi (TARBİL) Eskice Mevki istasyonundan alınan 2016 yılına ait güneş radyasyonu (W/m^2), rüzgâr şiddeti (m/s), rüzgâr yönü, sıcaklık 2 m ($^{\circ}\text{C}$), ultraviyole radyasyon indis, toprak üstü 5 cm sıcaklık ($^{\circ}\text{C}$) verileri kullanılmıştır. Veriler 10 dakikalık periyotlarla kaydedilmiştir. Her veri grubundan toplamda 52576 adet kayıt bulunmaktadır. İstasyon 41.0722°N , 28.5782°E koordinatlarında olup rakım 50 m’dir. İstasyonun kule yüksekliği 10 m’dir.



Şekil 1. Eskice Mevki istasyonu (41.0722 ° N, 28.5782 ° E, rakım : 50 m) (Url-1)

Çalışmada kullanılacak olan veriler, tahmin modellerinde kullanılmadan önce birtakım ön işlemlerden geçirilmelidir. Veri madenciliği belirli bir süreci kapsamaktadır. Bu sürecin başlangıcında veri temizleme, veri bütünleştirme, veri indirgeme, veri dönüştürme gibi adımlar vardır (Özkan, 2016). Verilerin tamamına ve çalışmada kullanılmak üzere seçilen aylardaki verilere SPSS programı kullanılarak kayıp veri analizi yapılmıştır. Bu analiz sonucunda kayıp içeren veri gruplarına SPSS programında lineer interpolasyon yöntemi kullanılarak kayıp verilerin yerine yenisi konulmuştur.

Veri madenciliği süreçlerinden olan ve veri dönüştürme kapsamında uygulanan bir diğer işlem normalizasyon işlemidir. YSA modellerinde verilerin kullanılmadan önce uygun olarak düzenlenmesi model başarımını artırmaktadır. Bu nedenle YSA modellerinde kullanılacak tüm veriler min-max yöntemi ile Eşitlik (1) kullanılarak dönüştürülmüştür. Bu dönüştürme işlemi sonucunda tüm veriler 0 ile 1 arasındaki sayısal değerlere dönüştürülür (Özkan, 2016).

$$Y^* = \frac{X - X_{\min(\text{ay})}}{X_{\max(\text{ay})} - X_{\min(\text{ay})}} \quad (1)$$

Bu eşitlikte Y^* dönüştürülmüş değerleri, X gözlem değerlerini $X_{\min(\text{ay})}$ ilgili ay için en küçük gözlem değerini, $X_{\max(\text{ay})}$ ilgili ay için en büyük gözlem değerini ifade etmektedir.

3. YÖNTEM

3.1 Çoklu Lineer Regresyon

Regresyon analizi, iki ya da daha çok değişken arasındaki ilişkiyi modellemede kullanılan metotlar arasında en yaygın olanıdır. Bağımlı değişkeni tahmin etmek için kurulan modelde giriş olarak tek bir bağımsız değişken kullanılıyorsa tekli regresyon, birden fazla bağımsız değişken kullanılıyorsa çoklu regresyon analizi olarak adlandırılır. Bağımlı ve bağımsız değişken ya da değişkenler arasındaki ilişki doğrusal (lineer) olabileceği gibi eğrisel de olabilir. Regresyon analizi ile bağımlı ve bağımsız değişkenler arasındaki ilişkinin varlığı, eğer ilişki var ise bunun gücü hakkında bilgi edinilebilir. Çoklu Lineer Regresyon'da n adet bağımsız değişken ($X_1, X_2, X_3 \dots X_n$) ile bağımlı değişken (Y) arasındaki doğrusal ilişki Eşitlik (2)'deki gibidir (Damodar, 2004).

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n + e \quad (2)$$

Burada Y bağımsız değişkeni, X_n bağımlı değişkenlerin doğrusal bir fonksiyonu olarak ele alınır. Eşitlikteki b_n değerleri modeldeki katsayılar olup, b_0 doğrunun Y eksenini kestiği noktayı göstermektedir. Eşitlikteki e ise hata terimi olarak tanımlanmıştır. Buradaki katsayılar en küçük kareler yöntemi ile bulunmaktadır. En küçük kareler yaklaşımı kullanılarak Eşitlik (3)'te verilen tahmin hatası sıfıra indirgenmeye çalışılmaktadır (Aslan, Yavasca ve Yasar, 2011a).

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

Eşitlik (3)'te n veri sayısı, y_i gözlemlenmiş orijinal veri, \hat{y}_i modelin tahmin ettiği değer, **SSE** (Sum of Squares for Error) ise tahmin hatalarının karesel toplamıdır. Bu yöntemde SSE değişkeni, her katsayı farklılaştırıldıktan sonra sıfıra eşitlenmeye veya minimize edilmeye çalışılır. Bu şekilde Eşitlik(2)'de gösterilen regresyon denklemi elde edilir. Eşitlik (4)'te üç katsayı (a, b, c) ve iki bağımsız değişkenden (x_1, x_2) oluşan bir lineer regresyon denklemi ($y = a + bx_1 + cx_2$) için katsayıların hesaplanmasını sağlayan ve en küçük kareler yöntemi kullanılarak elde edilen denklem görülmektedir (Aslan, Yavasca ve Yasar, 2011b).

$$\begin{bmatrix} n & \sum_{i=1}^n x_{1i} & \sum_{i=1}^n x_{2i} \\ \sum_{i=1}^n x_{1i} & \sum_{i=1}^n x_{1i}^2 & \sum_{i=1}^n x_{1i} \cdot x_{2i} \\ \sum_{i=1}^n x_{2i} & \sum_{i=1}^n x_{1i} \cdot x_{2i} & \sum_{i=1}^n x_{2i}^2 \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_{1i} \cdot y_i \\ \sum_{i=1}^n x_{2i} \cdot y_i \end{bmatrix} \quad (4)$$

3.2 Yapay Sinir Ağları

Yapay sinir ağları insan beyninin yapısı ve çalışmasından esinlenerek geliştirilmiş, ağırlığı olan bağlantılarla birbirine bağlanmış, her birinin kendi belleği olan düğüm noktalarından oluşan paralel ve dağıtılmış bilgi saklama ve işleme yapılarıdır. YSA'lar için kısaca biyolojik sinir hücrelerinin yapısını ve çalışmasını taklit eden bilgisayar programlarıdır denilebilir. YSA'lar kendi kendine öğrenme yeteneğine sahiptirler. Öğrenmenin yanı sıra ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptirler. YSA'ların başlıca uygulama alanları sınıflandırma, tahmin ve modelleme olarak belirtilebilir (Elmas, 2016).

Öztemel (2016) ise YSA'ların kullanım alanlarını şu şekilde belirtmektedir. Sınıflandırma, örüntü tanıma, olasılık fonksiyon kestirimleri, ilişkilendirme veya örüntü eşleştirme, sinyal filtreleme, zeki ve doğrusal olmayan kontrol, zaman serisi analizleri, veri sıkıştırma, doğrusal olmayan sinyal işleme, doğrusal olmayan sistem modelleme ve optimizasyon.

Yapay sinir ağlarında bilgiler, ağın içindeki bağlantıların ağırlıklarında depolanır. Bir yapay ağda öğrenme işlemi, istenen bir işlevi yerine getirecek şekilde ağırlıkların ayarlanması sürecidir. YSA'da öğrenme işlemi düğümler arasındaki bağlantı ağırlıklarının değiştirilmesi ile gerçekleştirilir. Öğrenme işlemi belirli kurallara göre yapılır ve bu konuda değişik yöntemler geliştirilmiştir. YSA bir sürü yapay sinir hücresinin bir araya gelip bağlanması ile oluşur. Genel olarak sinir hücreleri giriş, gizli ve çıkış katmanı olmak üzere üç katman halinde sıralanırlar (Öztemel, 2016).

Eşitlik (5)'te bir yapay sinir hücresinin çıkış sinyali verilmiştir. YSA'larda girişler (x_i) çevreden aldıkları bilgileri sinir hücresine getirir. Girişler dış dünyadan veya kendinden önceki sinirden gelebilir. Girişlerin her biri belirli bir ağırlık (w) değeri ile çarpılır. Ağırlıklar girişlerin sinir hücresi üzerindeki etkisini belirleyen uygun katsayılarıdır. Bir ağırlığın büyüklüğü ilgili girişin sinir ağına güçlü bağlanması ve önemli olması anlamına gelir. Ağırlıklarla çarpılan giriş değerleri ve eşik değeri (θ) toplanır. Bazı durumlarda toplama işlevi yerine en az, en çok, çoğunluk veya normalleştirme algoritması gibi işlevler kullanılabilir. Elde edilen bu toplam (v_i) sonucu oluşturmak için bir etkinlik işlevinden (f) geçirildikten sonra y_i çıkışı elde edilir (Elmas, 2016).

$$y_i = f \left(\sum_{j=1}^n w_{ij} x_i + \theta_j \right) \quad (5)$$

Yapay sinir hücresindeki etkinlik işlevi kendisine gelen girdiyi işleyerek hücrenin üreteceği çıktıyı belirler. Birçok etkinlik işlevi kullanılmaktadır. Etkinlik işlevleri doğrusal veya doğrusal olmayan biçimlerde olabilir. Step ve sign fonksiyonları genellikle örüntü tanıma ve sınıflandırmada, sigmoid ve tanjant sigmoid fonksiyonu geri yayımlı (back propagation) ağlarda kullanılmaktadır. Doğrusal aktivasyon fonksiyonu ise genellikle lineer yakınlılaşmada kullanılmakta ve çıkışı ağırlıklandırılmış nöron girişleriyle denk tutmaktadır (Nabiyev, 2016).

3.3 Model Performanslarının Değerlendirilmesinde Kullanılan Yöntemler

Çalışma kapsamında geliştirilen modellerin başarımını değerlendirmek üzere istatistiksel değerlendirme yöntemlerinden Korelasyon Katsayısı (R), Normalize Kök Ortalama Karesel Hata (Normalized Root Mean Square Error - nRMSE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE) metotları kullanılmıştır. Eşitlik(6)'da R'in hesaplanmasında kullanılan denklem görülmektedir (Zang ve diğerleri, 2019). Eşitlik(7)'de RMSE değerlerinin hesaplanmasında kullanılan denklem görülmektedir (Çelik, Teke ve Yıldırım, 2016). Eşitlik(8)'de nRMSE değerinin hesaplanmasında kullanılan denklem görülmektedir (Sun ve diğerleri, 2018b). Eşitlik(9)'da MAPE değerlerinin hesaplanmasında kullanılan denklem görülmektedir (Aghajani, Kazemzadeh ve Ebrahimi, 2016).

$$R = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)(y_i - \bar{y}_i)}{\sqrt{[\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)^2] \cdot [\sum_{i=1}^n (y_i - \bar{y}_i)^2]}} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (7)$$

$$nRMSE = \frac{RMSE}{\bar{y}_i} \times 100 \quad (8)$$

$$MAPE(\%) = \frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\bar{y}_i} \right|}{n} \times 100 \quad (9)$$

n : Veri adedi

y_i : Gözlemlenmiş değer

\bar{y}_i : Gözlemlenmiş değerlerin ortalaması

\hat{y}_i : Tahmin edilen değer

$\bar{\hat{y}}_i$: Tahmin edilen değerlerin ortalaması

R'in -1 ile +1 arasında, bir değerde olması beklenir. R'in -1 veya +1'e yakın olduğu modeller daha başarılıdır. R'nin sifıra yakın olduğu modeller başarısızdır. Başarım ölçümünde RMSE, nRMSE ve MAPE değerlendirmesinde ise değerler ne kadar düşük çıkarsa modeller o kadar daha başarılı sayılır (Nourani, Komasi ve Mano, 2009).

RMSE, hatanın ortalama büyüklüğünü ölçen karesel bir değerlendirmedir. Hataların ortalamaları alınmadan önce kareleri alındığından, RMSE büyük hatalara nispeten daha yüksek ağırlık verir (Li ve Shi, 2010). Bu çalışmada mevsimleri temsilen seçilen dört farklı aya ait veri setleri ile çalışıldığından değerlendirmenin daha sağlıklı yapılabilmesi için RMSE her ay için gözlemlenmiş değerlerin ortalamasına bölünerek nRMSE yüzde cinsinden elde edilmiştir (Sun ve diğerleri, 2018c).

MAPE, tahmin değerlerine ait mutlak hata yüzdelерinin ortalamasını göstermektedir. MAPE değerlendirmesinde %10'nun altındaki değerler modellerin çok iyi olduğunu, %10 ile %20 arasındaki değerler iyi, %20 ile %50 arasındaki değerlerin kabul edilebilir ve %50'nin üstündeki değerler ise modellerin yanlış ve hatalı olabileceğini işaret etmektedir (Alkan, Öztürk ve Tosun, 2018).

4. UYGULAMA

Bu çalışmanın uygulama aşamasında Eskice Mevki istasyonuna ait veriler mevsimleri temsilen dört gruba ayrılmıştır. Her mevsim için başlangıç ayı seçilmiştir. İlkbahar mevsimini temsilen Mart ayı, yaz mevsimini temsilen Haziran ayı, sonbahar mevsimini temsilen Eylül ayı, kış mevsimini temsilen Aralık ayı verileri kullanılarak aylar bazında ayrı olarak modelleme çalışması gerçekleştirilmiştir.

4.1 Çoklu Lineer Regresyon ile Tahmin Modelleme

Çalışmanın bu aşamasında istatistiksel yöntemlerden çoklu lineer regresyon yöntemi kullanılarak mevsimleri temsilen seçilen aylar bazında güneş radyasyonu için tahmin çalışması yapılmıştır. Tahmin çalışmasında meteorolojik veriler kullanılarak ileriye yönelik 24 saat sonrası için 10 dakikalık adımlarla güneş radyasyonu tahmin edilmeye çalışılmıştır. SPSS programı kullanılarak adimsal (stepwise) yöntem ile çoklu lineer regresyon modeli uygulanmıştır.

Adimsal olarak adlandırılan regresyon yöntemi kalan karelerin toplamı üzerinde en büyük etkiye sahip olan değişkenlerin eklenmesine veya silinmesine dayanır (Ghorbani ve diğerleri, 2016). Bu yöntemde bağımsız değişkenler bağımlı değişkenle aralarındaki ilişkiye göre en güçlü ilişkiye sahip olandan başlanarak sırayla modele dahil edilir. Bağımlı değişkenle olan anlamlı ilişkisine göre ve modele olan anlamlı katkılarına göre bağımsız değişkenler her adımda modelde tutulur ya da modelden atılır. Yöntem modele girecek veya modelden çıkarılacak değişken kalmayınca kadar devam eder. Verilerin %70'i modeli kurmak ve eğitmek için kullanılmış, kalan %30'luk kısım ise test için saklı veri olarak ayrılmıştır. Bu seçimler rastgele değil belirli aralıklar verilerek yapılmıştır.

Güneş radyasyonu regresyon denklemleri Eşitlik(10)'da görüldüğü gibi bulunmuştur.

$$\begin{aligned}
 \text{Mart Ayı : } Y_{gr+k} &= 6,442 + 0,533X_{gr} + 4,1X_{rs} + 39,28X_{uv} + 2,036X_{ry} - 12,771X_{s2m} + 14,117X_{s5cm} \\
 \text{Haziran Ayı : } Y_{gr+k} &= 8,793 + 0,295X_{gr} + 70,857X_{uv} + 12,101X_{rs} + 13,563X_{s5cm} - 11,895X_{s2m} \\
 \text{Eylül Ayı : } Y_{gr+k} &= 592,34 + 0,51X_{gr} + 67,82X_{uv} + 3,887X_{rs} - 32,726X_{s5cm} + 5,934X_{s2m} - 1,843X_{ry} \\
 \text{Aralık Ayı : } Y_{gr+k} &= -2,93 + 0,766X_{gr} + 3,385X_{rs} + 20,065X_{uv}
 \end{aligned} \tag{10}$$

- Y_{gr+k} : 24 saat sonraki güneş radyasyonu çıkışı (t + k)
 X_{rs} : Rüzgâr şiddeti giriş (t)
 X_{gr} : Güneş radyasyonu giriş (t)
 X_{uv} : UV radyasyon indis giriş (t)
 X_{s5cm} : Toprak üstü 5 cm sıcaklık giriş (t)
 X_{s2m} : Sıcaklık 2 m giriş (t)
 X_{ry} : Rüzgâr yönü giriş (t)

4.2 YSA ile Tahmin Modelleme

Çalışma kapsamında İleri Beslemeli (Feed Forward), Geri Yayılımlı (Back Propagation) YSA modelleri kullanılmıştır. Kurulan modellerde bir adet giriş katmanı, bir adet gizli katman, bir adet çıkış katmanı olmak üzere toplam 3 katman bulunmaktadır. Girişte 6 adet veri grubu olduğu için giriş katmanı 6 nöron dan oluşmaktadır. Çıkış katmanında ise güneş radyasyonu olan tek parametre olduğundan çıkış katmanı tek nöronludur.

YSA modellerinde gizli katmanlardaki nöron sayısını belirlemek için kesin bir kural yoktur. Genellikle belirli sayıdan başlamak suretiyle ve kademeli artırma ile modeller denenerek uygun sayı bulunmaya çalışılır. Olması gerekenden az belirlenen gizli nöron sayısı modellerin yetersiz sonuçlar vermesine, gereğinden fazla belirlenen gizli nöron sayısı da modellerin verileri ezberlemesine ve sadece eğitim verilerinde iyi sonuçlar verip test verilerinde başarısız olmasına neden olabilir (Çakır, 2018).

Gizli katmandaki hücre sayısının belirlenmesinde kesin bir kural olmamakla beraber genellikle gizli katman hücre sayısı giriş katmanındaki hücre sayısının iki katını geçmez. Ayrıca piramit kuralı denilen bir yöntem kullanılır. Bu kurala göre bir piramidin yapısına benzer şekilde giriş katmanından çıkış katmanına doğru hücre sayısının azalması gerektiği varsayılır. Giriş ve çıkış katmanındaki hücre sayıları sırayla n ve m olmak üzere piramit kuralına göre Eşitlik (11) ile gizli hücre sayısı bulunur (Yücesoy, 2011).


$$\sqrt{m * n} \quad (11)$$

Bu çalışmada gizli katmandaki nöron sayısını belirlemek için çok sayıda deneme yapılmıştır. Piramit kuralı da dikkate alınarak yapılan denemelerde gizli katmanda 3 nöron kullanıldığı zaman genel olarak en iyi sonucun alındığı görülmüştür. Bu nedenle gizli katmandaki hücre sayısının 3 olmasına karar verilmiştir. Çalışmada geliştirilen YSA modelleri aşağıdaki şekilde isimlendirilmiştir.

YSA (Giriş Katmanı Nöron Sayısı, Gizli Katman Nöron Sayısı, Çıkış Katmanı Nöron Sayısı)


YSA modellerinin uygulanması için MATLAB R2016b programının nntool aracı ve ilaveten yazılan kodlardan yararlanılmıştır. Şekil 2'de MATLAB'ta kurulan YSA modelinin şeması görülmektedir. Kurulan YSA modellerinin genel özellikleri aşağıdaki gibi seçilmiştir.

| | |
|-----------------------------------|--|
| YSA Mimarisi | : İleri Beslemeli Geri Yayılımlı Çok Katmanlı Algılayıcı |
| Eğitim algoritması | : Levenberg Marquand (<i>trainlm</i>) |
| Gizli katman transfer fonksiyonu | : Tanjant Sigmoid (<i>tansig</i>) |
| Gizli katman nöron sayısı | : 3 |
| Çıktı katmanı transfer fonksiyonu | : Tanjant Sigmoid (<i>tansig</i>) |
| Öğrenme oranı | : 0,2 |
| Momentum | : 0,8 |
| Maksimum İterasyon | : 3000 |



Şekil 2. MATLAB YSA model şeması (MATLAB 2016, nntraintool)

YSA modeli mevsimleri temsilen seçilen dört ayın her biri için ayrı olarak uygulanmış ve sonuçlar aylar bazında gösterilerek değerlendirilmiştir. YSA ile uygulama işlemine başlamadan önce her aya ait veri setinin ilk %70'i sinir ağlarını eğitmek için belirlenmiştir. Kalan %30'luk kısım ise eğitimi tamamlanan modelleri test etmek için saklı veri olarak ayrılmıştır. Veriler seçilirken rastgele değil, belirli aralık verilerek seçim işlemi yapılmıştır. Şekil 3'de şematik olarak gösterilen YSA(6,3,1) modelinde giriş olarak t zamandaki X_{gr} , X_{rs} , X_{uv} , X_{s5cm} , X_{s2m} , X_{ry} verileri verilmiş, çıkışta ise 24 saat sonraki güneş radyasyonu (Y_{gr+k}) tahmin edilmiştir.



Şekil 3. YSA(6,3,1) modelinin şematik gösterimi

5. SONUÇLAR

Güneş radyasyonu tahmin modellemesinde tahmin zamanından 24 saat öncesine ait meteorolojik veriler (rüzgâr şiddeti, güneş radyasyonu, UV radyasyon indisi, toprak üstü 5cm sıcaklık, sıcaklık 2m, rüzgâr yönü) kullanarak yaklaşık 8-10 günlük bir zaman diliminde 10 dakikalık zaman adımlarıyla güneş radyasyonu değerlerinin tahminine çalışılmıştır. Çizelge 1'de modellerin başarımlarını göstermektedir. Eğitim ve test sonuçları bütün aylar için $\alpha < 0.01$ seviyesinde istatistiksel anlamlıdır. ÇLR modelleri ile en yüksek başarı Haziran ayında elde edilmiştir. Haziran ayındaki ÇLR modelinin R, nRMSE ve MAPE değerleri sırasıyla 0.902, %53.9, %36.74 olarak bulunmuştur. Sonuç olarak Haziran ayında ÇLR modellerinin güneş

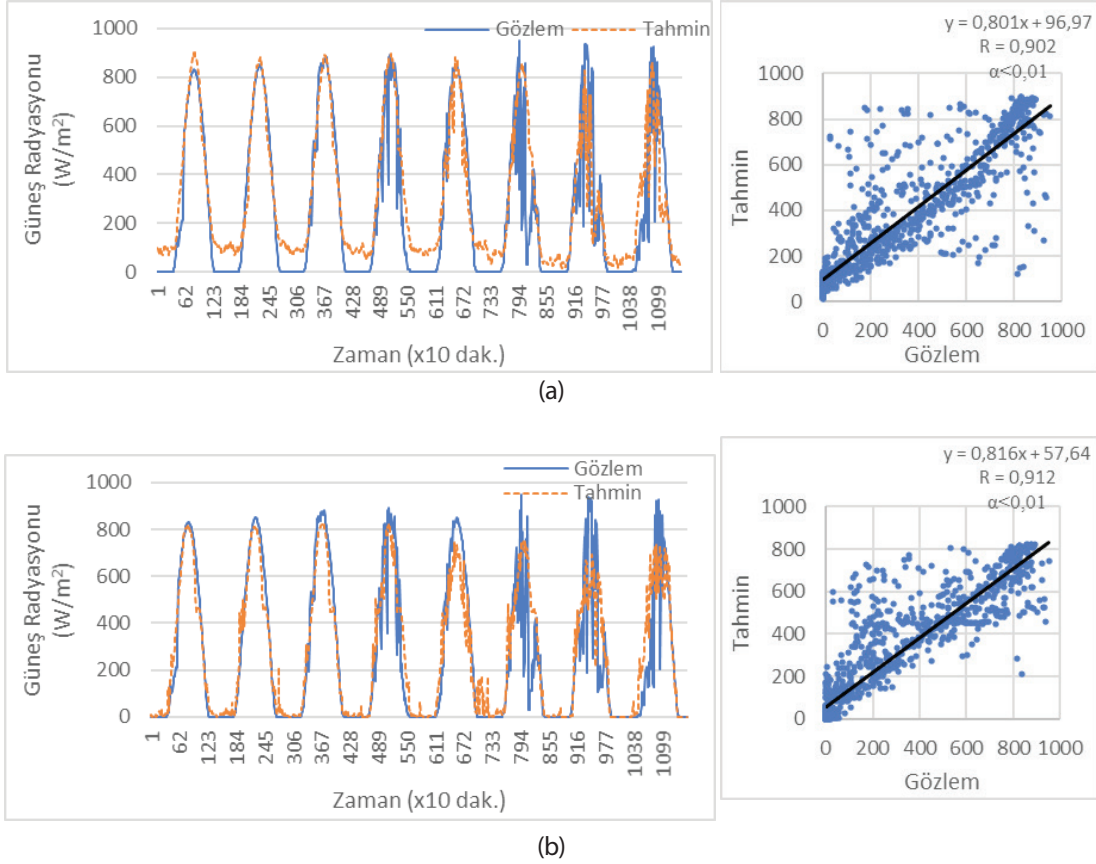
radyasyonu tahmininde yeter güvenilirlikte ($\alpha < 0.01$) kullanılabilceği vurgulanabilir. Bulgular Mart, Eylül ve Aralık ayının sonuçlarına göre ÇLR modellerinin bu aylarda tahmin için kullanılmasının uygun olmadığını göstermektedir (Çizelge 1).

Sonuçlara göre YSA modelleri tahmin çalışmasında ÇLR modellerinden seçilen bütün aylarda daha başarılı olmuştur. YSA ile yapılan tahmin çalışmasında en iyi sonuçlar yine Haziran ayında elde edilmiştir. Haziran ayında YSA modelinin R, nRMSE ve MAPE değerleri sırayla 0.912, %48.5, %28.21 olarak bulunmuştur. YSA modelleri güneş radyasyonu tahmininde Haziran ve Eylül aylarında diğer aylara göre daha başarılı olmuştur. Fakat Mart ve Aralık ayları için YSA modellerinin güneş radyasyonu tahmin çalışmalarında kullanılmasının uygun olmadığı ve geliştirilmesi gerektiği vurgulanabilir (Çizelge 1).

Çizelge 1. Güneş radyasyonu (W/m^2), model başarımlarının karşılaştırılması

| Aylar | Model | Eğitim Verileri (%70) | | | | Test Verileri (%30) | | | |
|---------|------------|-----------------------|--------|-----------|----------|---------------------|--------------|-------------|--------------|
| | | R | RMSE | nRMSE (%) | MAPE (%) | R | RMSE | nRMSE (%) | MAPE (%) |
| Mart | ÇLR | 0,771 | 103,82 | 104,8 | 65,62 | 0,640 | 158,58 | 119,5 | 68,74 |
| | YSA(6,3,1) | 0,827 | 91,73 | 92,6 | 52,19 | 0,744 | 142,86 | 107,7 | 60,02 |
| Haziran | ÇLR | 0,876 | 149,26 | 55,4 | 34,16 | 0,902 | 140,93 | 53,9 | 36,74 |
| | YSA(6,3,1) | 0,921 | 120,49 | 44,7 | 25,00 | 0,912 | 126,98 | 48,5 | 28,21 |
| Eylül | ÇLR | 0,929 | 92,08 | 50,7 | 28,10 | 0,726 | 163,93 | 118,4 | 94,56 |
| | YSA(6,3,1) | 0,945 | 81,55 | 44,9 | 21,93 | 0,775 | 146,14 | 105,5 | 52,99 |
| Aralık | ÇLR | 0,824 | 53,73 | 105,4 | 55,02 | 0,596 | 53,55 | 175,1 | 102,58 |
| | YSA(6,3,1) | 0,869 | 47,00 | 92,2 | 43,83 | 0,687 | 47,81 | 156,8 | 69,09 |

Şekil 4'te çalışmada kullanılan aylar içerisinde en iyi sonuçların alındığı Haziran ayına ait ÇLR ve YSA modellerinin gözlem-tahmin zaman grafikleri ve saçılma grafikleri görülmektedir. Güneş radyasyonu tahmininde ÇLR modelinin kestiremediği minimum değerleri YSA modelinin başarı ile tahmin ettiği vurgulanabilir.



Şekil 4. Güneş radyasyonu (W/m^2), Haziran ayı test verileri (a) ÇLR (b) YSA modellerinin gözlem-tahmin zaman grafikleri ve saçılma grafikleri

Her mevsimdeki meteorolojik olaylar ve etkileri farklı olduğundan dolayı güneş radyasyonu tahmin çalışmalarında daha güvenilir sonuçlar elde edebilmek için modellemelerin mevsimsel ve mümkünse aylık olarak yapılması gerektiği vurgulanabilir. Çalışmada geliştirilen YSA modellerine dayalı olarak güneş enerji sistemlerinde olası dalgalanmalara karşı erken uyarı sistemleri geliştirilebilir. Bu çalışmada elde edilen bulguların İstanbul Büyükçekmece İlçesi ve civarında mevcut bulunan güneş enerji sistemlerinin enerji verimliliğinin artırılmasında, ayrıca gelecekte kurulması planlanan sistemlerin kurulum ve işletim aşamalarında yararlı olması beklenmektedir.

Conflict of Interests/Çıkar Çatışması

Authors declare no conflict of interests / Yazarlar çıkar çatışması olmadığını belirtmişlerdir.

Teşekkür

Yazarlar veri destekleri için TARBİLe, değerli önerileri için Prof. Dr. Ali GÜNEŞ ve Doç. Dr. Metin ZONTUL'a teşekkürü borç bilirler.

6. KAYNAKÇA

Aghajani, A., Kazemzadeh, R., ve Ebrahimi, A. 2016. "A novel hybrid approach for predicting wind farm power production based on wavelet transform, hybrid neural networks and imperialist competitive algorithm", *Energy Conversion and Management*, 121, 232-240.

Alkan, Ö., Öztürk, A., ve Tosun, S. 2018. "Rüzgâr ve Güneş Santrallerinde Kısa Dönem Enerji Üretim Tahmini İçin Matematiksel Modellerin Oluşturulması", *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6(1), 188-195.

Aslan, Y., Yavasca, S., ve Yasar, C. 2011. "Long term Electric Peak load forecasting of Kutahya using different approaches", *International Journal on Technical and Physical Problems of Engineering*, 3(2), 87-91.

Bou-Rabee, M., Sulaiman, S. A., Saleh, M. S., ve Marafi, S. 2017. Using artificial neural networks to estimate solar radiation in Kuwait , *Renewable and Sustainable Energy Reviews*, 72, 434-438.

Çakır, F. S. 2018. *Yapay Sinir Ağları*, I.Baskı, Nobel Akademik Yayıncılık, Ankara.

Çelik, Ö., Teke, A., ve Yıldırım, H. B. 2016. The optimized artificial neural network model with Levenberg–Marquardt algorithm for global solar radiation estimation in Eastern Mediterranean Region of Turkey, *Journal of Cleaner Production*, 116, 1-12.

Damodar, N. G. 2004. *Basic Econometrics*, 4th edition, The McGraw-Hill ,New York.

Elmas, Ç. 2016. *Yapay Zeka Uygulamaları*, III. Baskı, Seçkin Yayıncılık, Ankara.

Erdil, A., ve Arcaklioglu, E. 2013. The prediction of meteorological variables using artificial neural network, *Neural Computing and Applications*, 22(7-8), 1677-1683.

Fan, J., Wu, L., Zhang, F., Cai, H., Zeng, W., Wang, X., ve Zou, H. 2019. Empirical and machine learning models for predicting daily global solar radiation from sunshine duration: A review and case study in China., *Renewable and Sustainable Energy Reviews*, 100, 186-212.

Ghofrani, M., Azimi, R., ve Youshi, M. 2019. *Pattern Recognition and Its Application in Solar Radiation Forecasting*, IntechOpen.

Ghorbani, M. A., Khatibi, R., FazeliFard, M. H., Naghipour, L., ve Makarynsky, O. 2016. Short-term wind speed predictions with machine learning techniques., *Meteorology and Atmospheric Physics*, 128(1), 57-72.

Kılıç, F. Ç. 2015. Güneş Enerjisi, Türkiye'deki Son Durumu ve Üretim Teknolojileri. *Engineer & The Machinery Magazine*, 56(671), 28-40, available in https://www.mmo.org.tr/sites/default/files/09677e0899d72e8_ek%281%29.pdf , last accessed March 2019

Li, G., ve Shi, J. 2010. On comparing three artificial neural networks for wind speed forecasting., *Applied Energy*, 87(7), 2313-2320.

Long, H., Zhang, Z., ve Su, Y. 2014. Analysis of daily solar power prediction with data-driven approaches., *Applied Energy*, 126, 29-37.

Nabiyev, V. V. 2016. Yapay Zeka, V. Baskı, Seçkin Yayıncılık, Ankara.

Nourani, V., Komasi, M., ve Mano, A. 2009. A multivariate ANN-wavelet approach for rainfall-runoff modeling., 23(14), 2877-2894.

Özkan, Y. 2016. Veri Madenciliği Yöntemleri, III. Baskı, Papatya Yayıncılık Eğitim, İstanbul.

Öztemel, E. 2016. Yapay Sinir Ağları, IV. Baskı, Papatya Yayıncılık, İstanbul.

Rahman, M. M., B. Mostafiz, S., Paatero, J. V., ve Lahdelma, R. 2014. Extension of energy crops on surplus agricultural lands: A potentially viable option in developing countries while fossil fuel reserves are diminishing., Renewable and Sustainable Energy Reviews, 29, 108-119.

Sun, S., Wang, S., Zhang, G., ve Zheng, J. 2018. A decomposition-clustering-ensemble learning approach for solar radiation forecasting., Solar Energy, 163, 189-199.

Yılmaz, E. A., ve Öziç, H. C. 2018. Türkiye'nin Yenilenebilir Enerji Potansiyeli Ve Gelecek Hedefleri., ODÜ Sosyal Bilimler Araştırmaları Dergisi (ODÜSOBİAD), 8(3), 525-535.

Yücesoy, M. 2011. Temizlik kâğıtları sektöründe yapay sinir ağları ile talep tahmini., Dotor Tezi, İTÜ Fen Bilimleri Enstitüsü, İstanbul.

Zang, H., Cheng, L., Ding, T., Cheung, K. W., Wang, M., Wei, Z., ve Sun, G. 2019. Estimation and validation of daily global solar radiation by day of the year-based models for different climates in China., Renewable Energy, 135, 984-1003.