[1144]

ADANA BÖLGESİ İÇİN GÜNLÜK TOPLAM GÜNEŞ ENERJİSİNİN VIIRS SENSÖRÜNE AİT VERİLER KULLANILARAK TAHMİN EDİLMESİ

Kazım KABA[1], H. Mustafa KANDIRMAZ[2]

[1]Çukurova Üniversitesi, Fizik Bölümü, 01330, Adana, kkaba46@gmail.com
[2]Prof.Dr., Çukurova Üniversitesi, Fizik Bölümü, 01330, Adana, h.mustafakandirmaz@gmail.com

ÖZET

Bu çalışmada, Adana ve çevresi için günlük toplam güneş ışınım şiddeti, makine öğrenme algoritması olan destek vektör makineleri (DVM) yöntemi kullanılarak tahmin edilmiştir. Çalışmada, atmosfer dışı güneş ışınımı (G), istasyon koordinatları (Enlem, Boylam, Yükseklik) ve kutupsal yörüngeli Suomi-NPP VIIRS algılayıcısının 12 kanal verileri arasından en uygun girdiler belirlenmiştir. G, Enlem, Boylam ve VIIRS algılayıcısının 8 solar ve 2 termal kanalı en iyi girdi seti olarak kullanılmıştır. Modelin eğitim ve test aşamalarını değerlendirmek ve yapılan diğer çalışmalarla kıyaslamak amacıyla tahmin edilen değerler yer istasyonlarınca ölçülen değerler ile kıyaslanarak hata hesaplamaları yapılmıştır. Test verileri için ortalama yüzde mutlak hata (MAPE) 15.1433, yüzde ortalama karesel hatanın karekökü (%RMSE) 16.5059 ve belirleme katsayısı (R^2) 0.8659 olarak bulunmuştur.

Anahtar Sözcükler: Destek vektör makineleri, Global güneş enerjisi, Parlaklık sıcaklığı, Suomi NPP VIIRS, Yansıma.

ABSTRACT

ESTIMATION OF DAILY GLOBAL SOLAR RADIATION USING VIIRS DATA AROUND ADANA

In this study, daily total solar radiation was estimated for Adana and its surrounding area using support vector machines (SVM) which is a machine learning algorithm method. In the study, the most appropriate inputs have been determined among extra-terrestrial solar radiation (G), the stations coordinate (latitude, longitude, altitude) and 12 channel data of polar orbiting Suomi-NPP VIIRS sensor. G, latitude, longitude and 8 solar and 2 thermal channels of VIIRS sensor were found as the best input set. In order to evaluate the training and testing process of the model and to comparing with other studies, the error calculations were done comparing the estimated values with the ground measured values. For test data, mean absolute percent error for the (MAPE) 15.1433, percent root mean square error (%RMSE) 16.5059 and the coefficient of determination (R2) were calculated to be 0.8659.

Keywords: Support vector machines, Global solar energy, Brightness temperature, Suomi NPP VIIRS, Reflectance.

1.GİRİŞ

Dünyanın birinci ve en önemli enerji kaynağı güneştir. Yere ulaşan güneş ışınları yaşamı ve onun devamını mümkün kılmaktadır. Yüzeye gelen güneş enerjisi, iklimsel, tarımsal, hidrolojik ve enerji uygulamaları için kritik öneme sahiptir. Dolayısıyla enerji değerlerinin zamansal ve alansal bakımdan bilinmesi yapılacak çalışmaları doğrudan etkileyecek ve verimli sonuçlar alınmasını sağlayacaktır.

Türkiye güneş ışınım şiddeti ve süresi bakımından yüksek değerlere sahiptir. Ülkemizde güneş ışınım şiddeti meteorolojik istasyonlarda noktasal olarak ölçülmektedir. Mevcut ölçüm değerleri kullanılarak veri olmayan yerler için interpolasyon yöntemiyle tahmin yapılmaktadır. Bu yöntemle yapılan tahmin özellikle ölçüm yapılan istasyonlardan uzaklaştıkça yüksek hata içermektedir. Dolayısıyla interpolasyon yöntemi ile üretilen enerji haritaları hassas ve kritik önem taşıyan çalışmalar için yetersiz kalabilmektedir. Bu yüzden özellikle istasyonlar arasında kalan alanlar için enerji değerlerinin yüksek doğrulukla tahmin edilmesi gerekmektedir.

Enerji tahminine yönelik, dünyada ve ülkemizde birçok çalışmalar yapılmıştır ve halen yapılmaktadır. Araştırmacılar, geçmişten günümüze çeşitli yöntemlerle yüzeye gelen güneş enerjisini tahmin etmişlerdir. Geleneksel yöntem diye bilinen ve öncülüğünü Angström-Prescott metodunun çektiği güneşlenme süresi, sıcaklık gibi meteorolojik değişkenleri kullanan istatistiksel çalışmalar bir hayli fazladır (Despotovic ve ark, 2015; Mohammadi ve ark, 2016). Bir diğer yöntem ise süper bilgisayarların kullanıldığı meteorolojik verilerin simülasyonunu yapan fiziksel yöntemlerdir (Gautier ve ark, 1980; Cogliani ve ark, 2007). Çalışmalar da yer ölçümleri ve uydu verileri veya her ikisi de birlikte girdi olarakta kullanılabilmektedir (Rusen ve ark, 2013). Kullanılan veri tipine göre modeller yer veya uydu tabanlı ya da hibrit olarak tanımlanmaktadır.

Son zamanlarda makine öğrenme algoritmalarını kullanan yeni yöntemler geliştirilmiştir. Bu algoritmalardan Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) en yaygın kullanılan yöntemlerdir. Yine bu yöntemlerde de yer ve uydu verileri kullanılarak enerji tahminleri yapılabilmektedir. Araştırmacılar çalışmalarında bu yöntemlerin geleneksel regresyon analizine dayanan çalışmalardan daha iyi sonuçlar verdiğini göstermişlerdir. (Behrang ve ark, 2010; Quesada-Ruiz ve ark, 2015; Belaid ve Mellit, 2016; Shamshirband ve ark, 2016).

Bu çalışmada Adana ve çevresindeki istasyonlarda ölçülen güneş ışınımı değerleri ve kutupsal yörüngeli Suomi-NPP VIIRS algılayıcına ait reflektans ve parlaklık sıcaklığı değerlerini veren kanal verileri kullanılarak bölgenin güneş ışınım şiddeti DVM yöntemiyle tahmin edilmiştir.

2.ÇALIŞMA ALANI VE KULLANILAN VERİLER

Çalışma bölgesi olarak Adana ve civarı seçilmiştir. Günlük toplam güneş enerjisi tahmini için Adana ve çevresindeki Meteoroloji genel Müdürlüğü (MGM) istasyonlarının verileri kullanılmıştır. Kullanılan istasyonlara ait bilgiler Çizelge 1 de görülmektedir. Çalışmada tahmin için atmosfer dışı güneş ışınımı ve Suomi-NPP uydusundaki VIIRS sensörünün 12 kanalına ait veriler modele girdi olarak kullanılırken istasyonlarda ölçülen günlük toplam güneş enerjisi çıktı olarak kullanılmıştır. VIIRS sensörünün 5 tane I (Imagery), 16 tane M (Moderate) ve 1 tane de DNB (Day Night Band) olmak üzere 22 kanalı bulunmaktadır. I kanalları 375 m yersel çözünürlüğe sahipken diğer kanallar 750 m çözünürlüktedir. M kanallarından M01, M03, M12 ve M13 hariç 12 M kanalı kullanılmıştır. Kullanılan kanallardan 3 tanesi parlaklık sıcaklığı (BT, Brightness Temperature) ve 9 tanesi de yansıtma (r, Reflectance) kanalıdır. Kullanılan kanallara ait bilgiler tablo 2 de (Seaman, 2013) verilmiştir.

Çizelge 1. Çalışmada kullanılan yer istasyonlarının konumları.

İstasyon Kodu	Enlem (^oK)	Boylam (^oD)	Yükseklik (m)	İstasyon Adı
17250	37.9587	34.6795	1211	Niğde
17351	37.0041	35.3443	23	Adana
17866	38.0240	36.4823	1344	Göksun
17906	37.5480	34.4867	1453	Ulukışla

Çizelge 2. Çalışmada kullanılan VIIRS algılayıcısına ait kanallar.

VIIRS Kanal isimleri	Merkez Dalga boyu (µm)	Öncelikli uygulama alanı
M02	0.445	Okyanus, Aerosol
M04	0.555	Okyanus, Aerosol
M05	0.672	Okyanus, Aerosol
M06	0.746	Atmosferik düzeltme
M07	0.865	Okyanus, Aerosol
M08	1.24	Bulut parçacık boyutu
M09	1.38	Sirrüs bulut örtüsü
M10	1.61	Kar örtüsü
M11	2.25	Bulutlar
M14	8.55	Bulut tepe özellikleri
M15	10.76	Deniz Yüzey Sıcaklığı
M16	12.01	Deniz Yüzey Sıcaklığı

Çizelge 1'de çalışılan istasyonlara ait kod numaraları, konum bilgileri (Enlemi Boylam ve yükseklik), ile istasyon isimleri verilmiştir. Çizelge 2'de ise VIIRS sensörünün kullanılan kanallarının kod adları, kanalların merkezi dalga boyları ve kanalların öncelikle kullanıldığı uygulama alanları verilmiştir.

Çalışmada kullanılan girdilerden atmosfer dışı güneş ışınımı aşağıdaki formül (Duffie ve Beckman, 2013) ile

hesaplanır;

$$G = \left(\frac{24*60}{\pi}\right) * G_{sc} * d * [\omega_s \sin\varphi \sin\delta + \cos\varphi \cos\delta \sin\omega_s] \quad (1)$$

G atmosfer dışı günlük ışınım (MJ/m^2/gün), G_{sc} güneş sabiti ve G_{sc} = 0.0820 MJ/m^2/dakika değerindedir. Denklemde d ters bağıl Dünya-Güneş uzaklığı (inverse relative distance Earth-Sun) olup,

$$d = 1 + 0.033\cos(2\pi J/365) \quad (2)$$

denklemi ile hesaplanır. Burada J jülien günü 'dür, ω_s gün doğumu ve gün batımı anındaki saat açısıdır ve denklem 3 ile hesaplanır.

$$\omega_s = \cos^{-1}[-\tan\varphi \tan\delta] \quad (3)$$

denklemlerdeki φ enlem açısıdır ve δ deklinasyon açısı olup denklem 4 ile hesaplanır.

$$\delta = 0.409 * \sin\left[\frac{2\pi J}{365} - 1.39\right] \quad (4)$$

3.DESTEK VEKTÖR MAKİNELERİ (DVM)

Destek vektör makineleri Vapnik tarafından geliştirilmiş eğitimli öğrenmeye dayanan yapay zeka algoritmasıdır. Ortaya konulduğu zamandan beri örüntü tanıma, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılmaktadır (Vapnik ve ark, 1997). Öncelikle sınıflandırma için kullanılan yöntem daha sonra Cortes ve Vapnik tarafından regresyon problemlerinin çözümü için genişletilmiştir (Cortes ve Vapnik, 1995). DVM öğrenmesi genel hatanın üst sınırını minimize eden yapısal risk minimizasyonu prensibine dayanır (Cortes ve Vapnik, 1995). Regresyon problemlerinde veya doğrusal ayrılamayan veri problemlerinde daha yüksek boyutlu özellik uzayı lineer olmayan bir kernel metoduyla değerlendirilir. Eğitim verisi kuadratik programlama yardımıyla doğrudan yüksek boyutlu özellik uzayına haritalanır. Bu uzayda bir veya daha fazla hiperdüzlem oluşturulur. Bu hiperdüzlemler destek vektörleri olarak adlandırılan seçilmiş veriler dikkate alınarak oluşturulan maksimum aralığa (marjin) sahiptir. Yüksek boyutlu uzaydaki çözüm bir dışbükey optimizasyona dönüştürülür. Bu nedenle yerel minimum problemleri yoktur. YSA tersine, DVM çözümü tektir. Kernel metotları özellikle regresyon problemlerinde büyük öneme sahiptir. DVM bu avantajları ve verimliliği onu mühendislik veya bilimsel problemler için popüler bir metot yapmaktadır.

Vapnik teorisine dayanan DVM denklemleri aşağıda verilen eşitlik 5'ten eşitlik 9'a kadar ifade edilmiştir. $\{x_i, d_i\}_i^n$ şeklinde verilen bir veri seti alalım. Burada x_i örnek verinin girdi uzay vektörü, d_i hedef/çıktı değerler ve n veri sayısıdır. DVM eşitlik 5 ve 9 ile verilen fonksiyonu tahmin etmeyi amaçlar (Ch ve ark, 2014).

$$f(x) = \omega\varphi(x) + b \quad (5)$$

$$R_{SVMs}(C) = \frac{1}{2} \parallel \omega \parallel^2 + C\frac{1}{n}\sum_{i=1}^{n} L(x_i, d_i) \quad (6)$$

burada $\varphi(x)$ girdi uzay vektörü x'in haritalandığı yüksek boyutlu uzay özelliğini ifade eder. ω normal vektördür ve b bir skalerdir. L genel bir kayıp fonksiyondur ve $C\frac{1}{n}\sum_{i=1}^{n} L(x_i, d_i)$ ampirik hatayı ifade eder. ω ve b parametreleri üst ve alt ilave sapmayı temsil eden pozitif ξ_i ve ξ_i^* değişkenleri denkleme girdikten sonra eşitlik 7'deki düzenlenmiş risk fonksiyonunun minimize edilmesiyle bulunur (Ch ve ark, 2014).

$$Minimize\ R_{SVMs}(\omega, \xi^{(*)}) = \frac{1}{2} \parallel \omega \parallel^2 + C\sum_{i=1}^{n}\left(\xi_i + \xi_i^{(*)}\right) \quad (7)$$

$$\text{bağlı olarak} \begin{cases} d_i - \omega\varphi(x_i) + b_i \le \varepsilon + \xi_i \\ \omega\varphi(x_i) + b_i - d_i \le \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \ge 0, i = 1,2,3,\dots,l \end{cases} \quad (8)$$

burada $\frac{1}{2} \parallel \omega \parallel^2$ düzenleme terimidir. C düzenleme terimi ve ampirik hata arasındaki farkı ayarlamak için kullanılan hata ceza faktörüdür. ε eğitim verisinin doğruluğuna yaklaşım için kayıp fonksiyonudur ve l eğitim veri setindeki eleman sayısıdır.

DVM yaygın kullanılan kernel fonksiyonlarından radyal bazlı (rbf), lineer, polinom, ve sigmoid fonksiyonları aşağıda verilmiştir.

Radyal: $\exp(-\gamma|x - x'|^2)$
Lineer: $\langle x, x' \rangle$
Polinom: $(\gamma\langle x, x' \rangle + r)^d$
Sigmoid: $\tanh(\gamma\langle x, x' \rangle + r)$

Eşitlik 7 bir Lagrange çarpanının eklenmesiyle ve optimum kısıtlamalar ile çözülebilir ve böylece genel bir fonksiyon eşitlik 9 ile verilir.

$$f(x, \alpha_i, \alpha_i^*) = \sum_{i=1}^{n} (\alpha_i - \alpha_i^*) K(x, x_i) + b \tag{9}$$

burda $K(x_i, x_j)$ terimi kernel fonksiyonu olmak üzere $K(x_i, x_j) = \varphi(x_i)\ \varphi(x_j)$ şeklinde ifade edilir.

Makine öğrenme algoritmalarında yüksek doğrulukta bir tahmin için öncelikle modelin iyi eğitilmiş olması gerekir. Eğitim aşamasında model üretilecek hedef veriyi gördüğünden sonuçlar bu kısımda gerçek değerlerle daha tutarlıdır. Test aşamasında ise eğitim bölümünde öğrenilen örneklerin yanı sıra yeni girdilerle yeni değerler üretilmekte ve sonuçların doğruluğu genelde eğitim aşamasına göre biraz daha düşük çıkmaktadır. Bu nedenle öncelikle modelin eğitim aşamasında yüksek başarı yakalamak gerekmektedir. Bunun için ise eğitim veri seti bütün durumları yansıtacak genişlikte veya başka bir deyimle test veri seti eğitim veri setinin bir alt kümesi olacak şekilde ayarlanmalıdır. Ayrıca veride hatalı ve/veya aykırı değerlerin olması halinde veri setine filtre uygulanıp bu verilerden arındırılmış bir veri seti ile çalışılmalıdır.

3.1.Hata hesap indisleri

Modelin başarısını değerlendirmek için MAE (Ortalama mutlak hata), MAPE (Yüzde ortalama mutlak hata), RMSE (Ortalama karesel hatanın karekökü), %RMSE (Bağıl/yüzde RMSE)ve R^2 (Belirleme katsayısı) istatistiksel yöntemleri kullanılmıştır. Bu yöntemlerin matematiksel ifadeleri aşağıda verilmiştir.

$$MAE = \frac{\sum_{i=1}^{n} |E_i - M_i|}{n} \tag{10}$$

$$MAPE = \frac{100}{n} * \sum_{i=1}^{n} \frac{|E_i - M_i|}{M_i} \tag{11}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n} (E_i - M_i)^2}{n}} \tag{12}$$

$$\%RMSE = \sqrt{\frac{\sum_{i=1}^{n} (E_i - M_i)^2}{n}} * \frac{100 * n}{\sum_{i=1}^{n} M_i} \tag{13}$$

$$R^2 = \frac{\left[\sum_{i=1}^{n} (E_i - \bar{E})(M_i - \bar{M})\right]^2}{\sum_{i=1}^{n} (E_i - \bar{E})^2 \sum_{i=1}^{n} (M_i - \bar{M})^2} \tag{14}$$

burada E_i tahmin edilen değerler ve M_i ölçülen değerlerdir. $\bar{E}$ ve $\bar{M}$ tahmin ve ölçülen değerlerin ortalaması, n ise toplam veri sayısıdır.

4.BULGULAR

Çalışmada öncelikle tek bir tablo halinde hazırlanan veri seti girdi ve çıktı olmak üzere iki gruba ayrılarak normalize edilmiştir. Normalize edilen veri grupları %67 eğitim ve %33 test olmak üzere çapraz doğrulama (cross validation) yöntemiyle yine ikiye bölünmüştür. Uygun girdilerin belirlenmesi için istasyonlara ait konum bilgisi (Enlem, Boylam, Yükseklik), atmosfer dışı güneş ışınımı ve 12 VIIRS kanal verisi olmak üzere toplam 16 farklı değişken kullanılmıştır. En iyi sonucu verecek girdi kombinasyonunu tespit etmek amacıyla lineer DVM fonksiyonunu kullanan geri dönüşümlü özellik eleme (recursive feature elemination) metodundan faydalanmıştır. Bu algoritma öznitelikleri önem sırasına göre sıralamaktadır. Lineer DVM fonksiyonunun en iyi sonucu üretmesi için ceza parametresi C = 2.8 olarak bulunmuş ve girdilerin önem sırası belirlenmiştir.

Tahminde en iyi sonuca ulaşabilmek için kullanılacak en uygun fonksiyon ve onun parametrelerini belirlemek amacıyla DVM'nin üç çekirdek fonksiyonu (lineer, polinom ve radyal bazlı) test edilmiş ve bunlar arasında en uygun olanının da rbf kernel fonksiyonu olduğu saptanmıştır. C ve gama parametrelerinin optimum değerleri de C = 8 ve gama = 0.02 olarak tespit edilmiştir. Çalışmada en başarılı tahmin 13 girdi kullanılarak elde edilmiştir.

Modelden elenen en önemsiz üç özellik yükseklik, VIIRS M06 ve M14 kanalları olmuştur. Elde edilen bu bulgular ile güneş enerjisi tahmini gerçekleştirilmiştir.

5.SONUÇLAR

Modelin farklı kombinasyondaki girdilerle tekrar tekrar çalıştırılmasıyla öğrenme ve test aşamalarında en iyi sonuçlar elde edilmeye çalışılmıştır. Test sonuçlarında en başarılı tahmin 13 girdinin kullanılmasıyla elde edilmiştir. Bu modelle elde edilen eğitim ve test sonuçları Şekil 1'de görülmektedir.

Şekil 1 modelin eğitim ve test aşamalarının simülasyonunu göstermektedir. Üstteki grafik eğitim, alttaki grafik ise test sonucunda üretilen değerler ile gerçek (yer ölçümü) değerlerin grafiğidir. Grafiklerde kesikli mavi yer ölçümünü ve kesikli kırmızı yapılan tahmin değerlerini ifade etmektedir. Yatay eksenler veri setindeki veri sayısını ve düşey eksenler enerji değerlerini göstermektedir. Grafikler incelendiğinde hem eğitim hem de test aşamalarında enerjinin özellikle küçük değerleri olmak üzere uç değerlerin tahmininde model düşük başarı göstermiştir. Diğer ara değerlerde ise çok daha iyi sonuçlar üretilmiştir.

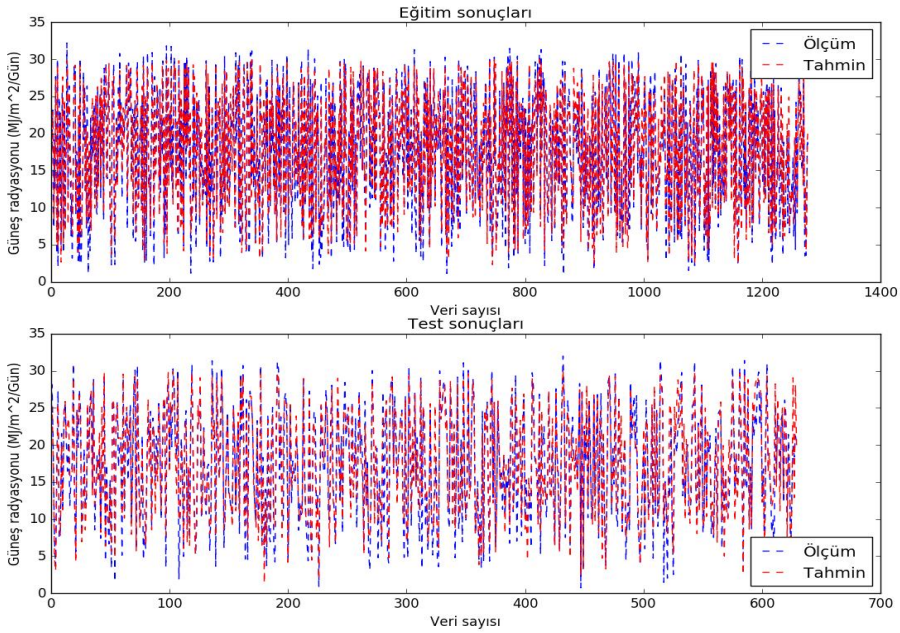

Şekil 1. Modelin eğitim ve test sonuçlarının karşılaştırılması.

Şekil 2 ise yer ölçümü ile yapılan tahminin dağılım grafikleridir. Şekil 2'de soldaki grafik eğitim verilerinin, sağdaki grafik ise test verilerinin dağılımıdır. Grafiklerde yatay eksenler yer istasyonlarında ölçülen enerji değerleri ve düşey eksenler de tahmin değerleridir. Grafikler üzerinde dağılım eğrisinin denklemi ve belirleme katsayısı (R^2) verilmiştir. R^2 eğitim verisi için 0.8735, test verisi için ise 0.8659 olarak bulunmuştur.

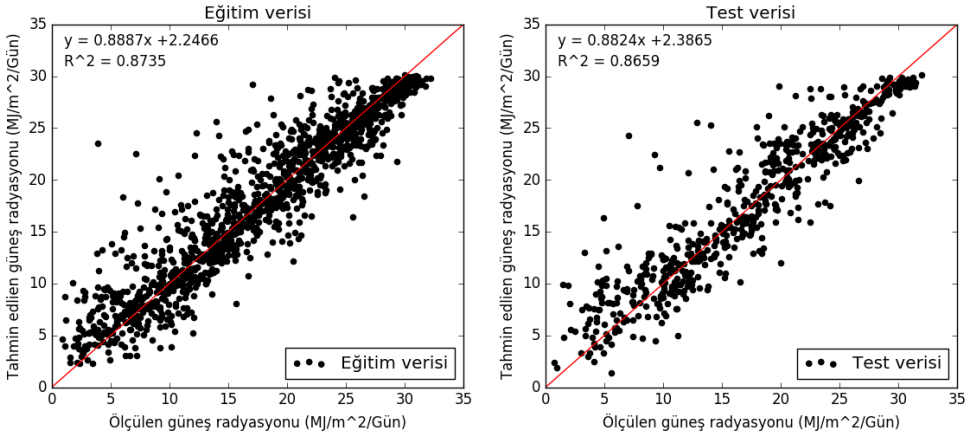

Şekil 2. Modelin eğitim ve test sonucu ölçülen ile tahmin değerlerinin dağılımı.

Çalışmanın sonuçlarını özetleyen istatistiksel hesaplamalar eğitim ve test aşaması olmak üzere Çizelge 3'te verilmiştir. Diğer taraftan yapılan son çalışmalar (Belaid ve Mellit,2016) DVM'in Yapay Sinir Ağlarına (YSA) göre daha iyi sonuçlar ürettiğini göstermektedir (Çizelge 4).

Çizelge 3. Hata hesapları.

Araştırmacı	Model	Mod	MAE (MJ/m^2/Gün)	MAPE	RMSE (MJ/m^2/Gün)	%RMSE	R^2(%)
Bu çalışma	DVM	Eğitim	1.9648	14.5356	2.8088	15.8006	0.8735
		Test	2.0120	15.1433	2.8528	16.5059	0.8659

Çizelge 4. Diğer çalışmalar (Belaid ve Mellit,2016).

Araştırmacı	Model	Mod	MAE (MJ/m^2/Gün)	MAPE	RMSE (MJ/m^2/Gün)	%RMSE	R^2(%)
S. Belaid ve A. Mellit	DVM	Eğitim	---	10.1370	2.7270	12.7420	0.8118
		Test	---	10.4580	2.7790	13.1720	0.8028
A. Linares-Rodriguez ve ark.	YSA	Eğitim	---	---	2.8300	13.5200	---
		Test	---	---	3.0160	14.2000	---
Moghaddamnia ve ark.	YSA	Eğitim	---	---	---	19.1000	0.8649
		Test	---	---	---	22.4000	0.8100

Çizelge 3 ve 4 incelendiğinde bu çalışmada elde edilen sonuçların diğer çalışmaların sonuçlarıyla oldukça yakın olduğu görülmektedir. Çalışmada özellikle R^2 değeri diğer çalışmalarda elde edilen değerlerden daha yüksek olarak bulunmuştur. Öte yandan RMSE değeri diğer değerlere yakın ancak MAPE değeri diğer değerlerden daha yüksektir. Sonuç olarak DVM modeli ve VIIRS uydu verileri kullanarak tahmin edilen enerji değerleri günlük tahmin için oldukça iyi kabul edilebilir. Ayrıca modele farklı parametrelerin girmesi ve/veya veri setindeki hatalı değerlerin elenmesi işlemi yapılarak sonuçların daha da iyileşmesi sağlanabilecektir.

KAYNAKLAR

Behrang, M.A., Assareh, E., Ghanbarzadeh, A., Noghrehabadi, A.R., 2010. The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. Sol Energy, 84, 8, 1468-80.

Belaid, S., Mellit, A., 2016. Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate. Energ Convers Manage, 118, 105-18.

Ch, S., Sohani, S.K., Kumar, D., Malik, A., Chahar, B.R., Nema, A.K., Panigrahi, B.K., Dhiman, R.C., 2014. A Support Vector Machine-Firefly Algorithm based forecasting model to determine malaria transmission. Neurocomputing, 129, 279-88.

Cogliani, E., Ricchiazzi, P., Maccari, A., 2007. Physical model SOLARMET for determinating total and direct solar radiation by meteosat satellite images. Sol Energy, 81, 6, 791-8.

Cortes, C., Vapnik, V., 1995. Support-Vector Networks. Mach Learn, 20, 3, 273-97.

Despotovic, M., Nedic, V., Despotovic, D., Cvetanovic, S., 2015. Review and statistical analysis of different global solar radiation sunshine models. Renew Sust Energ Rev, 52, 1869-80.

Duffie, J.A., Beckman, W.A., 2013. Solar engineering of thermal processes, Wiley New York, p.

Gautier, C., Diak, G., Masse, S., 1980. A Simple Physical Model to Estimate Incident Solar-Radiation at the Surface from Goes Satellite Data. J Appl Meteorol, 19, 8, 1005-12.

Mohammadi, K., Khorasanizadeh, H., Shamshirband, S., Tong, C.W., 2016. Influence of introducing various meteorological parameters to the Angstrom-Prescott model for estimation of global solar radiation. Environ Earth Sci, 75, 3.

Quesada-Ruiz, S., Linares-Rodriguez, A., Ruiz-Arias, J.A., Pozo-Vazquez, D., Tovar-Pescador, J., 2015. An advanced ANN-based method to estimate hourly solar radiation from multi-spectral MSG imagery. Sol Energy, 115, 494-504.

Rusen, S.E., Hammer, A., Akinoglu, B.G., 2013. Estimation of daily global solar irradiation by coupling ground measurements of bright sunshine hours to satellite imagery. Energy, 58, 417-25.

Seaman, C., 2013. Beginner's Guide to VIIRS Imagery Data. http://rammb.cira.colostate.edu/projects/npp/Beginner_Guide_to_VIIRS_Imagery_Data.pdf (10.08.2016).

Shamshirband, S., Mohammadi, K., Tong, C.W., Zamani, M., Motamedi, S., Ch, S., 2016. A hybrid SVM-FFA method for prediction of monthly mean global solar radiation. Theor Appl Climatol, 125, 1-2, 53-65.

Vapnik, V., Golowich, S.E., Smola, A., 1997. Support vector method for function approximation, regression estimation, and signal processing. Adv Neur In, 9, 281-7.