



# Süleyman Demirel Üniversitesi

## YEKARUM e-DERGI

### (Journal of YEKARUM)



Cilt 8 , Sayı 2 , 94-104 , 2023  
E - ISSN:1309-9388

## Regresyon Yöntemleri ile Güneş Enerjisi Tahmini

Fatmanur ATEŞ<sup>1\*</sup>, Ramazan ŞENOL<sup>2</sup>

<sup>1\*</sup> Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Elektrik – Elektronik Mühendisliği Bölümü, Isparta, Türkiye, (ORCID: 0000-0001-5465-2483), [fatmanurates@isparta.edu.tr](mailto:fatmanurates@isparta.edu.tr)

<sup>2</sup> Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Elektrik – Elektronik Mühendisliği Bölümü, Isparta, Türkiye (ORCID: 0000-0002-7078-3229), [ramazansenol@isparta.edu.tr](mailto:ramazansenol@isparta.edu.tr)

(İlk Geliş Tarihi 09/11/2023 ve Kabul Tarihi 22/11/2023)

### ÖZET:

Dünya üzerinde nüfusun artması ve sanayileşmenin hızlanmasıyla enerjiye olan ihtiyaçta artmaktadır. Enerji ihtiyacının karşılanması için temelde yenilenebilir ve yenilenemez enerji kaynakları kullanılmaktadır. Yenilenebilir enerji kaynakları doğaya zarar vermeyen ve sürekli olma özelliği taşıyan kaynaklar olduğundan son yıllarda kullanımı artış göstermektedir. Yenilenebilir enerji kaynaklarından biri olan güneş, elektrik enerjisi üretiminde kullanımı gün geçtikçe yaygınlaşan kaynaklardandır. Güneş enerjisinden elektrik enerjisinin üretimi pek çok farklı yöntemle yapılabilmektedir ve bu yöntemler geliştirilmektedir. Ancak güneşten elektrik enerjisi üretiminin sürekli ve istikrarlı olması için bölgenin güneş ışınımının belirlenmesi ve güneş enerji santrallerinin güneş ışınımı göz önünde bulundurularak kurulması önem arz eder. Bu çalışmada Amerikan Meteoroloji Derneği (AMS) 'nin düzenlemiş olduğu güneş enerjisi tahmin yarışması için oluşturulan ve kullanıma sunulan verilerden güneş enerjisi tahmini yapılmıştır. Veriler Oklahoma şehrinde “güneş enerjisi çiftlikleri” olarak hizmet veren 98 farklı güneş enerji istasyonundan alınmıştır. Kullanılan veri seti ile literatürde güneş enerjisi tahmini için bulunan mevcut modellere alternatif yapay zekâ modeli önermek ve sonuçların iyileştirilmesi amaçlanmıştır. Çalışmada torbalama (bagging), k en yakın komşu (KNN) ve aşırı gradyan artırma (XGB)’ dan oluşan yapay zekâ regresyon algoritmaları kullanılarak ve kullanılan algoritmaların hiper parametre ayarlamaları yapılarak model performanslarının iyileştirilmesi sağlanmıştır. Sonuçlar güneş enerjisi tahmin yarışması için belirlenen performans değerlendirme metriği olan ortalama mutlak hata (MAE) ile verilmiştir. Sonuçta en optimum performansın torbalama algoritması kullanılarak 1340765.665225403 MAE değeri ile elde edildiği belirlenmiştir.

**Anahtar Kelimeler:** Güneş Enerjisi Tahmini, Regresyon, Torbalama Algoritması

## Solar Energy Prediction by Regression Methods

### ABSTRACT

As the world's population increases and industrialization accelerates, the need for energy increases. Basically, renewable and non-renewable energy sources are used to meet energy needs. Since renewable energy sources do not harm nature and are sustainable, their use has increased in recent years. Sun, one of the renewable energy sources, is one of the sources whose use in electrical energy production is becoming more widespread day by day. The production of electrical energy from solar energy can be done by many different methods, and these methods are being developed. However, in order for the production of electrical energy from the sun to be continuous and stable, it is important to determine the solar radiation of the region and to establish solar power plants taking solar

radiation into consideration. In this study, solar energy prediction was made from the data created and made available for the solar energy prediction competition organized by the American Meteorological Society (AMS). The data was taken from 98 different solar power stations that serve as “solar farms” in Oklahoma City. With the data set used, it is aimed to propose an alternative artificial intelligence model to the existing models for solar energy forecasting in the literature and to improve the results. In the study, artificial intelligence regression algorithms consisting of bagging, k nearest neighbor (KNN) and extreme gradient boosting (XGB) were used and the model performances were improved by making hyperparameter adjustments of the algorithms used. The results are given by mean absolute error (MAE), which is the performance evaluation metric determined for the solar energy forecasting competition. As a result, it was determined that the most optimum performance was achieved with an MAE value of 1340765.665225403 by using the bagging algorithm.

**Keywords:** *Solar Energy Prediction, Regression, Bagging Algorithm*

## 1. GİRİŞ

Yenilenebilir kaynaklardan enerji üretimi çevre zarar vermemesi ve kaynakların sürekli olması gibi özellikleriyle son yıllarda kullanımı gittikçe yaygınlaşmaktadır. Yenilenebilir enerji kaynaklarına rüzgâr, dalga, güneş örnek olarak verilebilir. Yenilenebilir enerji kaynaklarından biri olan güneş, farklı yöntemler kullanılarak enerji elde edilen en sık kullanılan kaynaklardan biridir. Güneşten güneş kolektörleri, fotovoltaik paneller, güneş bacaları gibi yöntemlerle farklı miktarlarda enerji elde edilir. Bu yöntemlerden enerji eldesini etkileyen en önemli parametrelerden biri ışınımıdır. Işınım arttıkça üretilen enerji de artar. Güneşten elde edilecek enerji hava koşullarına bağlıdır.

Hava koşulları her zaman aynı değildir değişkenlik gösterir, dolayısıyla elde edilen enerjide de dalgalanma olur. Tüketicinin enerji talebide zamana göre değişkenlik gösterir. Dolayısıyla elde edilen enerjinin fazlası daha sonra kullanılmak üzere depolanır. Biyolojik, kimyasal, ısı vb. türlerde çok değişik depolama yöntemleri mevcuttur [1]. Yenilenebilir enerjinin uygun bir şekilde depo edilmesi ve daha sonra tekrar kullanılması için bir öngörü şarttır. Bu öngörüye yönelik yapılan bazı araştırmalar, hava durumu verileri ile istatistik ve makine öğrenmesi yaklaşımlarını kullanarak güneş enerjisi tahminini üzerinde yoğunlaşmaktadır. Güneş enerjisi tahminleri kısa ya da uzun vadeli olarak yapılabilmektedir [2].

Güneş enerjisi tahminine yönelik olarak Amerikan Meteoroloji Derneği (AMS)’de bir yarışma düzenlemiştir. Yarışmada en iyi kısa vadeli tahminleri sağlayan istatistik ve makine öğrenmesi yöntemlerini belirlemek amaçlanmıştır. Yarışma 2014 yılında kaggle’da düzenlenmiş olup, 98 Oklahoma Mesonet arazisine gelen toplam günlük güneş enerjisini tahmin etmek amaçlanmıştır. Bu arazide Amerika Birleşik Devletlerinde bulunan 144 Yerel Topluluk Tahmin Sisteminden (Global Ensemble Forecast Systems - GEFS)’ten alınan hava durumu verileri kullanılarak güneş enerjisinin tahmin edilmesinin gerekli olduğu güneş enerjisi

çiftlikleri bulunmaktadır [3]. AMS veri seti kullanılarak farklı çalışmalar yapılmıştır. Zameer vd., veri seti üzerinde Ridge Regresyon ve Rastgele Orman algoritmasını önermiş oldukları çalışmalarında Ortalama Mutlak Hata (MAE) değerlerini sırasıyla 2283598,75 ve 2275017,03 olarak elde etmişlerdir [4]. Díaz–Vico vd., Derin Evrimsel Sinir Ağları (DNN) ile MAE değerini 2561382.58 olarak elde etmişlerdir [5]. Saad vd., 11 farklı regresyon modeli ortalamasıyla MAE değerini 2010000 olarak elde etmişlerdir [2]. Araf vd., Ridge Regresyon ile MAE değerini 2215000 olarak elde etmişlerdir [3].

Aggarwal ve Saini AMS veri seti üzerinde LSR ve ileri beslemeli sinir ağından (FFNN) oluşan topluluk modellerinin en optimum performansı MAE değeri 2411989.61 olarak elde ettiğini ifade etmişlerdir [6]. Torres-Barran vd., çalışmalarında Rastgele Orman Regresyonunun (RFR), Gradyan Arttırılmış Regresyonun (GBR), Aşırı Gradyan Arttırma (XGB) gibi yapay zekâ metotlarının küresel ve yerel rüzgâr enerjisi tahminine ve ayrıca güneş radyasyonu problemine uygulanmasını incelemiştir. Güneş radyasyonunu tahmin etmek için AMS veri setini kullanmışlardır. GBR ile test, tahmin, eğitim MAE sonuçlarını sırasıyla 2191300, 1876700 ve 1705500 olarak bulurken; XGB ile sırasıyla 2190900, 1910400 ve 1360300 olarak elde etmişlerdir [7]. Nematirad ve Pahwa, radyasyon, sıcaklık, basınç, nem, rüzgâr hızı, rüzgar yönü, gün doğumu saati ve gün batımı saatinden oluşan veri setini Bayesian optimizasyonlu çok katmanlı bir algılayıcı (MLP) ve ANN kullanarak güneş radyasyonu tahmin etmeyi amaçlamışlardır. Pearson Korelasyon Katsayıları (PCC) uygulandığında ANN algoritması ile MAE değerini 109.45 olarak elde ederken, PCC olmadan ANN algoritması ile MAE değerini 111.24 olarak elde etmişlerdir [8].

Yarışma 2014 yılında düzenlenmesine rağmen veri seti üzerinde güneş enerji tahmininin iyileştirmesine yönelik çalışmalar halen devam etmektedir. Bu çalışmada K-En Yakın Komşu (KNN), Aşırı Gradyan Arttırma (XGB) ve torbalama algoritmaları AMS veri seti ile eğitilmiş ve sonuçlar verilmiştir. Modellerin performanslarını artırabilmek için bazı hiper parametre değerleri değiştirilmiş ayrıca değiştirilen parametreler ve değerleri tablolar ile verilmiştir. Çalışmada en optimum sonucu torbalama algoritması vermiştir. Torbalama algoritmasının içerisinde bulunan regresyon modelleri değiştirilerek en optimum sonuç “Decisiontreeregressor()” kullanılarak MAE değeri 1340765.665225403 olarak elde edilmiştir. Çalışmanın geri kalanı şu şekilde organize edilmiştir; ikinci bölümde çalışmada kullanılan veri seti ve makine öğrenme modelleri kısaca açıklanmıştır. Çalışmanın üçüncü bölümünde modellerin eğitiminden elde edilen bulgular verilmiştir. Çalışmanın dördüncü ve son bölümünde ise araştırma bulguları yorumlanmıştır.

## 2. MATERYAL ve METOT

Bu bölümde çalışmada kullanılan materyallerin kısaca açıklamaları verilmiştir ve çalışmanın yöntemi anlatılmıştır.

### 2.1. Veri Seti

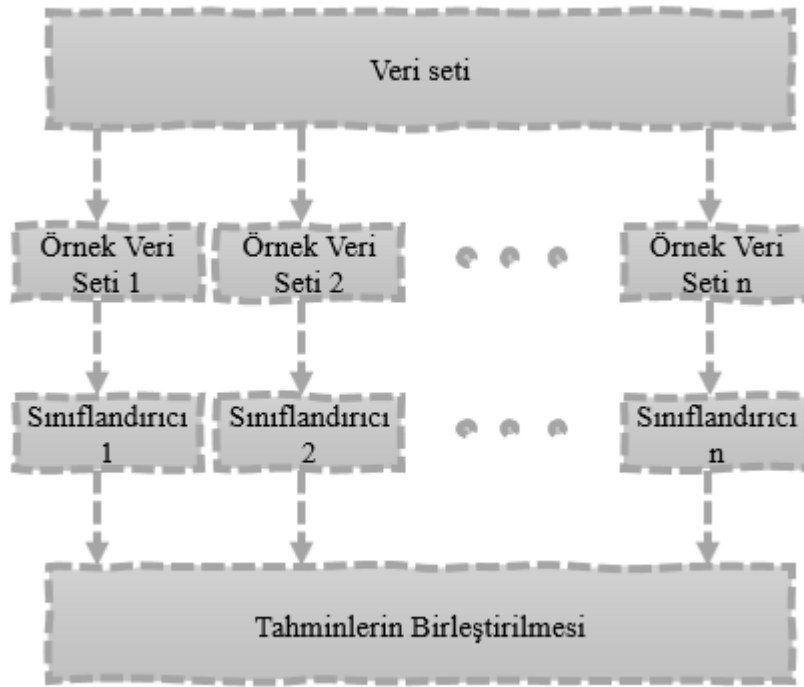
Çalışmada kullanılan veri seti kaggle platformundan alınmış olup, Amerikan Meteoroloji derneği 2013-2014 Güneş Enerjisi Tahmin Yarışması için eklenen verilerden oluşmaktadır. Veri setinin içerisinde bulunan veriler “güneş enerjisi çiftlikleri” olarak hizmet veren 98 Oklohoma Mesonet alanından elde edilen verilerden oluşmaktadır. Sayısal hava tahmini için giriş verileri NOAA/ESRL Yerel Topluluk Tahmin Sisteminden (GEFS- Global Ensemble Forecast System) elde edilmiştir (reforecast version 2) ve 15 meteorolojik veriden oluşmaktadır. Çalışmada mesonet noktalarına yakın olan GEFS istasyon verileri dikkate alınmıştır. Çıkış verisi ise ışıdır. Giriş ve çıkış verileri tablo 1’de verilmiştir. Veri seti ayrıca her istasyonun konum koordinatlarını ve yükseltisini de içermektedir. Veriler 1994-2007 yılları arasındaki verilerden oluşmaktadır [9]. Çalışmada uygulanan modeller için veri seti %25 test ve %75 eğitim için ayrılmıştır.

**Tablo 1.** Veri Setinde Bulunan Giriş ve Çıkış Verileri [9]

Değişken	Tanım
apcp_sfc	Yüzeyde 3 saatlik birikmiş yağış
dlwrf_sfc	Yüzeyde aşağı doğru uzun dalga ışıdırım akısı ortalaması
dswrf_sfc	Yüzeyde aşağı doğru kısa dalga ışıdırım akısı ortalaması
pres_msl	Ortalama deniz seviyesinde hava basıncı
pwat_eatm	Atmosferin tüm derinliği boyunca Yağışa çevirilebilir su oranı
spfh_2m	Yerden 2 m yükseklikte Özgül Nem
tcde_eatm	Atmosferin tüm derinliği boyunca toplam bulut örtüsü
tcolc_eatm	Tüm atmosferdeki sütuna entegre toplam yoğunlaşma.
tmax_2m	Yerden 2 m yükseklikte son 3 saatteki Maksimum Sıcaklık
tmin_2m	Yerden 2 m yükseklikte son 3 saatteki Minimum Sıcaklık
tmp_2m	Yerden 2 m yükseklikte mevcut sıcaklık
tmp_sfc	Yüzey sıcaklığı
ulwrf_sfc	Yüzeyde yukarı doğru uzun dalga radyasyonu
ulwrf_tatm	Atmosferin üst kısmında yukarıya doğru uzun dalga radyasyonu
uswrf_sfc	Yüzeyde yukarıya doğru kısa dalga radyasyonu

## 2.2. Torbalama (Bagging) Algoritması

Breiman tarafından geliştirilmiş olan topluluk öğrenme algoritmalarındandır [10]. Torbalama algoritması kısaca şu şekilde işler; orijinal eğitim veri seti olan  $D_{Eğitim}$ 'in boyutu  $N$  olsun,  $D_{Eğitim}$  değiştirilerek her biri  $N$  boyutundan olan  $n$  adet torba oluşturulur. Oluşturulan tüm torbalar  $D_{Eğitim}$ 'in alt kümesidir ve  $n$  örnek torbaları yinelenen örneklerle sahip olabilir. Burada  $n$  torba, sınıflandırıcı ile tahmin edilir ve etiketlenir. Nihai etiket ise çoğunluk oyu kullanılarak birleştirilir [11]. Torbalama yönteminde temel amaç birden fazla eğitim alt kümesi oluşturulup birkaç zayıf öğrenme modeli elde edilerek çeşitlilik oluşturabilmektir [12]. Akış şeması ise şekil 1 ile verilmiştir.



Şekil 1. Torbalama Algoritması

## 2.3. KNN Algoritması

Makine öğrenmesinde regresyon ve sınıflandırma problemlerinde kullanılan, gözlemlerin birbirlerine olan benzerliklerinden tahminlerin yapıldığı denetimli öğrenme metotlarından bir tanesidir [13]. Sınıfı bilinmeyen bir verinin ait olacağı sınıf ise şu şekilde belirlenir; eğitim veri setinde bulunan sınıfı bilinen verilerle karşılaştırılır, uzaklık ölçümleri yapılır,  $k$  kadar yakın komşuya bakılır ve en optimal sınıf atanır. Algoritmada  $k$  değerinin seçimi büyük öneme sahiptir [14]. Komşu yakınlıklarını belirlemede Öklid, Manhattan, Minkowski, Chebyshev gibi farklı mesafe ölçütleri kullanılabilir. Uzaklık ölçütlerinin formülleri denklem 1-4 ile verilmiştir [15].

$$d_{\text{öklid}}(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (1)$$

$$d_{\text{manhattan}}(p, q) = \sum_{i=1}^n |p_i - q_i| \quad (2)$$

$$d_{\text{chebyshev}}(p, q) = \max_i (|p_i - q_i|) \quad (3)$$

$$d_{\text{minkowski}}(p, q) = \sqrt[m]{\sum_{i=1}^n |p_i - q_i|^m} \quad (4)$$

Büyük eğitim setleri ile çalışmak gerektiğinde etkili sonuçlar elde edilebilir. Basit bir yapıya sahiptir. Hesaplama maliyeti yüksektir. Maliyeti azaltmak için temel bileşenler analizi gibi yöntemler uygulanabilir. Komşu sayısı, uzaklık ölçütü gibi hiper parametrelere duyarlıdır [16].

#### 2.4. XGB Algoritması

XGB algoritması, temeli gradyan artırma algoritmasından oluşan bir topluluk öğrenme algoritmasıdır. Aşırı öğrenmeyi kontrol edebilmek için daha düzenli bir model biçimlendirmesine sahiptir. Son yıllarda geliştirilmiş olan en başarılı algoritmalarından biridir ve iyi bir performans sağlar [17]. Model, birden fazla karar ağacını yapısında bulundurur. Her ağaç bir önceki ağacın artıklarına bakıp oluşturulacak yeni bir karar ağacı bulmak için bir gradyan algoritması kullanır. Nihai karar, birden fazla karar ağacı tarafından ortaklaşa verilir ve tüm ağaçların sonuçları, nihai tahmin sonucu olarak toplanır [18].

#### 2.5. Performans Değerlendirme Metrikleri

Performans değerlendirme metrikleri yapay zekâ modellerinin performanslarının birbirleriyle nicel kıyaslamalarının yapılabilmesine yardımcı olan değerlendirme kriterleridir. Korelasyon Katsayısı (R), Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (RMSE), vb. gibi pek çok farklı değerlendirme metrikleri bulunmaktadır [19]. Yarışma için belirlenen performans değerlendirme metriği MAE olduğundan, bu çalışmada MAE kullanılmıştır [9]. MAE, tahmin edilen değerlerin gerçek değere göre tutarsızlığını ve yakınlığı ölçer. Formülü denklem 5 ile verilmiştir [20].

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - x_i^*| \quad (5)$$

Denklem 5'te  $x_i$  gerçek değeri,  $x_i^*$  tahmin edilen değeri, N örneklem büyüklüğünü ifade eder [20].

### 3. ARAŞTIRMA SONUÇLAR ve TARTIŞMA

Çalışmada kaggle açık erişimli internet sitesinden alınmış olan “AMS 2013-2014 Solar Energy Prediction Contest” veri seti kullanılmıştır. Veri setine, normalizasyon gibi veri ön işleme uygulamaları yapılmıştır. Veri seti %75 eğitim, %25 test işlemi için ayrılmıştır. KNN, XGB ve torbalama algoritmalarının bazı hiper parametreleri değiştirilerek eğitim ve test işlemleri yapılmıştır. KNN için 1-10 aralığında k değerleri değiştirilerek modelin performans değişimi gözlenmiştir. KNN için k değerinin 3 seçildiği durumda modelin en optimum performansı gösterdiği belirlenmiştir. Seçilen k değeri arttıkça model performansının düştüğü gözlenmektedir. Ayrıca programın çalışma süresinde artış göstermektedir. Farklı k değerlerinde elde edilen MAE değerleri ve program çalışma süreleri tablo 2’de verilmiştir.

**Tablo 2.** KNN için 1-10 arası farklı k değerlerinde model performansının değişimi

K Değeri	MAE	Süre
1	1611833.6273619172	3.24 sn
2	1489634.819324813	3.8 sn
<b>3</b>	<b>1480927.963742027</b>	<b>4.42 sn</b>
4	1509196.4909355068	5.16 sn
5	1554303.4352154161	6.16 sn
6	1613056.1493372929	6.98 sn
7	1676736.1196944178	7.8 sn
8	1738196.5805825863	8.71 sn
9	1795060.6439032094	9.16 sn
10	1844720.7190158777	9.67 sn

Uygulanan XGB modeli için farklı öğrenme oranı değerlerinde modelin performans değişimi gözlenmiştir. Literatürdeki çalışmalarda uygulandığı gözlemlenen öğrenme oranları, model için seçilmiş, en optimum sonuçlar tablo 3’ten görüldüğü gibi öğrenme oranının 0.5 olduğu durumda elde edilmiştir.

**Tablo 3.** XGB için farklı öğrenme oranı değerlerinde model performansının değişimi

Öğrenme Oranı	MAE	Süre
0.001	14956449.390187692	49,8 sn
0.005	10081151.657945102	51 sn
0.01	6460161.9157223655	50.9 sn
0.05	2186570.4850411913	51.9 sn
0.1	2100255.174711521	51.5 sn
<b>0.5</b>	<b>1960014.6653900181</b>	<b>49.3 sn</b>

Veri setine KNN ve XGB’den sonra torbalama algoritması da uygulanmıştır. Torbalama algoritmasında ana veri setinden alt veri setleri oluşturulduktan sonra her alt veri setinin kararı

bir tahminleyici ile belirlenir. Burada tahminleyici seçimi de algoritma için bir hiper parametredir. Eğer seçim yapılmazsa varsayılan tahminleyici karar ağacıdır. Çalışmada farklı tahminleyiciler seçilerek torbalama algoritması eğitimleri tekrarlanmış, sonuçlar ve süreler tablo 4’te verilmiştir. Torbalama algoritmasının en optimum sonuçları “Decisiontreeregressor()” kullanılarak elde edildiği ifade edilebilir.

**Tablo 4.** Torbalama algoritması için farklı regresyon yapılarının model performansı üzerindeki etkisi

Regresyon Modeli	MAE	Süre
Decisiontreeregressor()	<b>1340765.665225403</b>	<b>1 dk 1sn</b>
Kneighborsregressor()	1564267.6458632224	1 dk 3sn
Lgbmregressor()	2133547.7094118665	37.1 sn
Randomforestregressor()	1352458.4308603683	1 sa 14 dk 11sn
Linearregression()	2451886.258907715	3.73 sn

#### 4. SONUÇ ve ÖNERİLER

Bu çalışmada AMS 2013-2014 Güneş Enerjisi Tahmin Yarışması için açık erişimli paylaşılan veri seti üzerinde literatürdeki çalışmalara alternatif olabilecek yöntemler uygulanmıştır. Çalışmadan şu sonuçlar çıkarılabilir;

- Makine öğrenme modellerinin farklı hiper parametre ayarlamaları yapılarak elde edilecek MAE değerleri optimum sonuca yaklaştırılabilir. Modellerden KNN en optimum değeri k komşu sayısı 3 olarak seçildiğinde MAE değeri 1480927.963742027 olarak vermiştir. XGB algoritması ise 0.5 öğrenme oranı ile en optimum sonucu vermiştir. Öğrenme oranı 0.5 seçildiğinde elde edilen MAE değeri 1960014.6653900181 olmaktadır. Torbalama algoritmasında alt veri seti tahminleyicisi karar ağacı seçildiğinde en optimum sonucu MAE değeri 1340765.665225403 olarak vermiştir.
- Makine öğrenme modellerinden en optimum sonuçlar MAE değeri 1340765.665225403 olarak belirlenen torbalama algoritması ile elde edilmiştir.
- Süre olarak en optimum zamanı KNN algoritması k değeri 1 olarak seçildiğinde 3.24 sn olarak vermiştir, ancak MAE değeri optimum elde edilen değere uzak kalmıştır.

Sonuçta çalışma için torbalama algoritmasının çalışmada uygulanan diğer modellere göre iyi performans verdiği gözlenmiştir ve önerilmiştir. Veri seti açık erişimli yayımlandığından, bu çalışma bilimsel araştırmalar için referans olarak kullanılabilir.



### **Teşekkür**

Çalışmada kullanılan “AMS 2013-2014 Solar Energy Prediction Contest” veri setinin açık kaynak verilerini internet sitelerinde (Kaggle) kullanıma açan herkese teşekkür ederiz.

### **Çıkar Çatışması Beyanı**

Yazarlar arasında çıkar çatışması yoktur.

### **Araştırma ve Yayın Etiği Beyanı**

Çalışma, araştırma ve yayın etiğine uygundur.

### **KAYNAKLAR**

- [1] M. Kozak ve Ş. Kozak, “Enerji depolama yöntemleri,” *Uluslararası Teknolojik Bilimler Dergisi*, 4(2), 17-29, 2012.
- [2] B. Saad, A. El Hannani, R. Errattahi, and A. Aqqal, “Assessing the impact of weather forecast models combination on the ams solar energy prediction,” *In 2020 Fourth International Conference On Intelligent Computing in Data Sciences (ICDS)*, pp. 1-5, 2020. IEEE. Doi: <https://doi.org/10.1109/ICDS50568.2020.9268767>
- [3] I. Araf, H. Elkhadiri, R. Errattahi, and A. El Hannani, “Ams solar energy prediction: A comparative study of regression models,” *In 2019 Third International Conference on Intelligent Computing in Data Sciences (ICDS)*, pp. 1-5. IEEE, 2019. Doi: <https://doi.org/10.1109/ICDS47004.2019.8942237>
- [4] A. Zameer, F. Shahid, M. Afzal, and M. Hassan, “Intelligent forecast models for daily solar energy prediction,” 2022.
- [5] D. Díaz–Vico, A. Torres–Barrán, A. Omari, and J. R Dorronsoro, “Deep neural networks for wind and solar energy prediction,” *Neural Processing Letters*, 46, pp. 829-844, 2017. Doi: <https://doi.org/10.1007/s11063-017-9613-7>
- [6] S. K. Aggarwal, and L. M. Saini, “Solar energy prediction using linear and non-linear regularization models: A study on AMS (American Meteorological Society) 2013–14 Solar Energy Prediction Contest,” *Energy*, 78, pp. 247-256, 2014. Doi: <https://doi.org/10.1016/j.energy.2014.10.012>
- [7] A. Torres-Barrán, Á. Alonso, and J. R. Dorronsoro, “Regression tree ensembles for wind energy and solar radiation prediction,” *Neurocomputing*, 326, pp. 151-160, 2019. Doi: <https://doi.org/10.1016/j.neucom.2017.05.104>

- [8] R. Nematirad, and A. Pahwa, “Solar radiation forecasting using artificial neural networks considering feature selection,” *In 2022 IEEE Kansas Power and Energy Conference (KPEC)*, pp. 1-4, IEEE, 2022. Doi: <https://doi.org/10.1109/KPEC54747.2022.9814765>
- [9] BoomerSooner, StormMiner, Will Cukierski, “AMS 2013-2014 Solar Energy Prediction Contest,” *kaggle.com*, 2013. [Online]. Available: <https://kaggle.com/competitions/ams-2014-solar-energy-prediction-contest> [Accessed: Oct. 22, 2023]
- [10] L. Breiman, “Bagging predictors,” *Machine learning*, 24, pp. 123-140, 1996.
- [11] S. Agarwal and C. R. Chowdary, “A-Stacking and A-Bagging: Adaptive versions of ensemble learning algorithms for spoof fingerprint detection,” *Expert Systems with Applications*, 146, 113160, 2020. Doi: <https://doi.org/10.1016/j.eswa.2019.113160>
- [12] T. Xia, P. Zhuo, L. Xiao, S. Du, D. Wang, and L. Xi, “Multi-stage fault diagnosis framework for rolling bearing based on OHF Elman AdaBoost-Bagging algorithm,” *Neurocomputing*, 433, pp. 237-251, 2021. Doi: <https://doi.org/10.1016/j.neucom.2020.10.003>
- [13] S. Tafralı, “K-en yakın komşu algoritması nasıl çalışır?” *miuul.com*, 2022. Erişim Adresi: <https://miuul.com/not-defteri/k-en-yakin-komsu-algoritmasi-nasil-calisir> [Erişim Tarihi: 05.11.2023]
- [14] G. Dilki ve Ö. D. Başar, “İşletmelerin İflas Tahmininde K-En Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması,” *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 19(38), 224-233, 2020.
- [15] E. Gül ve M. Kalyoncu, “Ağır Vasıta Hava Kompresörü Piston Segmanı Aşınması Durumlarında K-En Yakın Komşu Algoritmasının Sınıflandırma Performansının İncelenmesi,” *Avrupa Bilim ve Teknoloji Dergisi*, 78-90, 2020.
- [16] E. Taşcı ve A. Onan, “K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi,” *Akademik Bilişim*, 1(1), 4-18, 2016.
- [17] H. Abar, “Xgboost Ve Mars Yöntemleriyle Altın Fiyatlarının Kestirimi,” *Ekev Akademi Dergisi*, (83), 427-446, 2020.
- [18] S. Guan, Y. Wang, L. Liu, J. Gao, Z. Xu, and S. Kan, “Ultra-short-term wind power prediction method based on FTI-VACA-XGB model,” *Expert Systems with Applications*, 235, 121185, 2024. Doi: <https://doi.org/10.1016/j.eswa.2023.121185>
- [19] M. F. Bekçioğulları, B. Dikici, H. Açıkgöz ve Ö. F. Keçecioğlu, “Güneş Enerjisinin Kısa-Dönem Tahmininde Farklı Makine Öğrenme Yöntemlerinin Karşılaştırılması,” *EMO Bilimsel Dergi*, 11(22), 37-45, 2021.

Fatmanur ATEŞ, Ramazan ŞENOL, “Regresyon Yöntemleri ile Güneş Enerjisi Tahmini”, Yekarum e-Dergi, 8/2 (2023) 67-77

[20] Ö. A. Karaman ve Y. Bektaş, “Makine Öğrenmesi ve Optimizasyon Yöntemleri ile Uzun Dönem Elektrik Enerjisi Tahmini: Türkiye Örneği,” *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 5(2), 285-292, 2023.