

# Güneş Enerjisinin Kısa-Dönem Tahmininde Farklı Makine Öğrenme Yöntemlerinin Karşılaştırılması

## Comparison of different machine learning methods in short-term forecasting of solar energy

M. Fatih Bekçioğulları<sup>\*1</sup>, Bünyamin Dikici<sup>1</sup>, Hakan Açıkgöz<sup>1</sup>, Ö. Fatih Keçecioglu<sup>2</sup>

<sup>1</sup>Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Gaziantep

[mehmetfatih.bekciogullari@gibtu.edu.tr](mailto:mehmetfatih.bekciogullari@gibtu.edu.tr), [bunyamin.dikici@gibtu.edu.tr](mailto:bunyamin.dikici@gibtu.edu.tr), [hakan.acikgoz@gibtu.edu.tr](mailto:hakan.acikgoz@gibtu.edu.tr)

<sup>2</sup>Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kahramanmaraş

[fkececioglu@ksu.edu.tr](mailto:fkececioglu@ksu.edu.tr)

### Öz

Günümüzde, güneş enerji santrallerine yapılan yatırımlar her geçen gün kayda değer derecede artış göstermektedir. Güneş enerjisinin meteorolojik parametrelere bağlı olarak değişken olması enerji üretiminin planlanmasını nispeten zorlaştırmaktadır. Bu durum şebeke işletme problemlerine de yol açabileceğinden güneş enerjisi tahmini önemli görülmektedir. Bu çalışmada, makine öğrenmesi metodlarının kısa-dönemli güneş enerjisi tahmini yapabilirliği karşılaştırılmıştır. İlk olarak, Avustralya, Alice Springs’de bulunan bir güneş enerji merkezindeki 1B: Trina isimli santralin çıkış gücü verisi ve bölgedeki ölçüm istasyonundan alınan meteorolojik parametrelerden oluşan bir veri seti elde edilmiştir. Daha sonra gücü verisi Ampirik mod ayrıştırma yöntemi ile alt bileşenlerine ayrılmıştır. Bu çalışmada, güneş enerjisinin tahmini için Doğrusal Regresyon (DR), Destek Vektör Makinesi (DVM), Karar Ağacı Regresyonu (KAR), Gauss Süreç Regresyonu (GSR) ve Topluluk Regresyonu (TR) gibi en çok kullanılan yöntemler tercih edilmiştir. Bu yöntemlerin farklı tahmin ufuklarındaki tahmin performanslarını değerlendirmek için karşılaştırma çalışmaları gerçekleştirilmiştir. Bu çalışmalarda, tüm makine öğrenme yöntemleri için R, RMSE ve MAE gibi performans metrik sonuçları hesaplanmıştır. Elde edilen metrik sonuçlarına göre DVM’nin en iyi tahmin sonucunu sağladığı gözlemlenmiştir.

**Anahtar Kelimeler:** Ampirik mod ayrıştırıcı, Güneş Enerjisi, Makine Öğrenmesi, Tahmin

### Abstract

Nowadays, the investment on Photovoltaic (PV) power generation is increasing significantly day by day. The fact that solar energy is variable depending on meteorological parameters which makes it relatively difficult to plan energy generation. Since this problem may also lead to grid operations problems, solar energy forecasting is

considered important. In this study, the short-term solar energy forecasting capability of machine learning methods are compared. Firstly, a data set consisting of the output power data of the power plant named 1B: Trina in a solar power center in Alice Springs, Australia, and meteorological parameters taken from the measurement station in the region are obtained. Then, the power data is divided into sub-components with the empirical mode decomposition method. In this study, the most used methods such as Linear Regression (LR), Support Vector Machine (SVM), Decision Tree Regression (DTR), Gaussian Process Regression (GPR) and Ensemble Regression (ER) are preferred for solar energy forecasting. The comparison studies are carried out to evaluate the forecasting performances of these methods in different forecasting horizons. In these comparison studies, performance metric results such as R, RMSE and MAE are calculated for all machine learning methods. According to the metric results obtained, it has been observed that SVM provides the best forecasting result.

**Keywords:** Empirical mode decomposition, Solar energy, Machine learning, Forecast

### 1. Giriş

Günümüzün en büyük problemlerden biri olarak görülen küresel ısınmanın çözümü için bilim insanları arayış içindedir. Artan insan nüfusu ve sanayileşme ile birlikte fosil yakıtlar küresel ısınmanın en önemli nedenlerinden bir tanesidir. İnsan neslinin daha temiz ve yaşanabilir bir dünyada yaşayabilmesi için tüm dünyada enerji ihtiyacı için yenilenebilir enerji temelli santraller kurulmaya hızla devam edilmektedir. Bu enerji kaynaklarından biri olan Güneş enerjisi ise son yıllarda gittikçe artan bir ilgiye sahiptir. Tüm dünyada olduğu gibi ülkemizde de devletimizin verdiği teşviklerin de etkisiyle güneş enerjisinden elektrik üretiminde son yıllarda büyük sıçrama yaşanmıştır [1-3].

Güneş enerjisinin meteorolojik parametrelere bağlı olarak değişim gösterdiği bilinen bir gerçektir. Güneş radyasyonu, sıcaklık, nem, rüzgâr hızı ve bulutluluk gibi meteorolojik parametreler güneş enerjisinden elektrik üretimini doğrudan veya dolaylı olarak etkilemektedir. Meteorolojik değişimler güneş enerjisinde ani dalgalanmalara sebep olduğundan bu enerji ile devamlık gösteren enerji üretimi mümkün olmamaktadır. Ayrıca güneş enerjisinin belirsiz olması ve gün içinde meteorolojik parametrelere bağlı olarak dalgalanma göstermesi, enerjinin verildiği şebekede ani gerilim düşümlerine sebep olabileceği için kısa dönemli enerji tahmini önemli bir konu haline gelmiştir. Kısa dönemli yapılacak olan enerji tahmini ile güneş enerjisi dalgalanmasını kompanze ederek şebekede olabilecek işletme problemleri de böylelikle çözülebilmektedir. Güvenilir enerji tahmini ile üretilecek enerjinin öngörülebilir olması aynı zamanda enerji piyasasında enerjinin makul fiyatlarda pazarlanmasının önünü açmaktadır [4-6].

Son yıllarda Güneş enerji tahmini üzerine literatürde birçok çalışma yapılmıştır. Demolli vd. [7], Destek Vektör Makinesi (DVM), Lasso Regresyon ve kNN algoritmalarını kullanarak Niğde İli'nin güneş enerjisini tahmin etmişlerdir. Bu yöntemler birkaç performans metriği açısından karşılaştırılmış ve genel bir değerlendirme yapılmıştır. Elde edilen sonuçlardan DVM'nin daha iyi tahmin sonuçlarına sahip olduğu belirtilmiştir. Gök vd. [8] çalışmalarında Yapay Sinir Ağlarını (YSA) kullanmışlardır. Veri seti olarak güneş enerji santralinin 1 yıllık geçmiş güneş enerji verisi ile küresel tahmin sisteminden alınan bulutluluk verisi kullanılmıştır. 1 gün sonrası için güneş enerjisi tahmini yapılmıştır. Bulutluluk verisi kullanılan ağ ile kullanılmayan ağın karşılaştırıldığı bu çalışmada bulutluluk verisi kullanılan ağın tüm performans metrik sonuçlarında daha iyi performans sergilediği görülmüştür. Wolff vd. [9], güneş enerjisi tahmini için DVM tabanlı melez bir metod önermişlerdir. Veri setinde 15 dakika aralıklarla ölçülmüş güneş enerjisi çıkış gücü ve aynı aralıkla ölçülmüş sıcaklık verisi ile bulutluluk verisi kullanılmıştır. Optimize edilmiş DVM metodu ile alınan sonuçlar fiziksel yaklaşım tabanlı tahmin yöntemleri ile karşılaştırılmış ve elde edilen tüm metrik sonuçları kapsamlı bir şekilde değerlendirilmiştir. Mahmud vd. [10], coğrafi olarak güneş enerjisi bakımından en zengin yerlerden birisi olduğu belirtilen Avustralya'nın Alice Springs bölgesinde bulunan santralden elde edilen güneş enerjisinin tahmini için farklı makine öğrenme algoritmalarını kullanmışlardır. Veri seti olarak güneş enerjisi gücü ile birlikte bağıl nem, sıcaklık, radyasyon ve günlük yağış miktarı gibi meteorolojik parametreler kullanılmıştır. Tüm performans metrik sonuçlarından Rastgele Orman Algoritması (ROA) yönteminin en iyi sonuçları sağladığı görülmüştür. Massaoudi vd. [11], güneş enerji tahmini için doğrusal olmayan dışsal girdili otoregresif ağ ve Uzun-Kısa Süreli Bellek (UKSB) modeli tabanlı melez bir yöntem önermişlerdir. Tahmin ufku 1 ile 24 saat ilerisi olarak seçilmiş ve karşılaştırma çalışmaları yapılmıştır. Elde edilen sonuçlar ise birçok metrik bakımından incelenmiştir. Korkmaz vd. [12], güneş enerjisi tahmini için derin öğrenme tabanlı bir yöntem geliştirmişlerdir. İlk olarak santralin çıkışından elde edilen güç verileri Ampirik mod ayrıştırma yöntemi ile bileşenlerine ayrılmıştır. Daha sonra ise veri setindeki tüm girişler resme dönüştürülmüştür. Önerilen derin öğrenme yöntemin tahmin performansı regresyon metotları ile birçok yönden karşılaştırılmıştır. Yıldız vd. [13], kernel aşırı öğrenme makinesi temelli bir metodu Kilis ilinde bulunan

bir güneş enerji santralinin çıkış gücünü tahmin etmek için önermişlerdir. Önerilen tahmin metodunun performansını incelemek için detaylı karşılaştırma çalışmaları gerçekleştirilmiştir. Uğuz vd. [14] çalışmalarında 125 farklı bölgede kurulması planlanan güneş enerji santrallerinin çıkış gücünün farklı makine öğrenmesi metotları ile tahmin edilebilirliğini araştırmışlardır. Bu bölgelerden alınan rakım sıcaklık ve güneşlenme süresi gibi yedi farklı parametre kullanarak veri seti oluşturulmuştur. Bu veri seti ile farklı makine öğrenmesi metotlarından sonuçlar alınmıştır. Performans değerlendirme sonuçları YSA modelinin güneş enerjisinin tahmininde daha güvenilir sonuçlar sağladığını göstermiştir. Özdemir vd. [15] çalışmalarında YSA ve çift yönlü UKSB metotlarıyla güneş enerjisi güç tahmini yapmışlardır.

Bu çalışmada, güneş enerji tahmininde farklı regresyon yöntemlerinin performansları detaylı bir şekilde incelenmiştir. İlk olarak 2018-2019 yıllarını kapsayan bir veri seti Avusturalya'da bulunan Alice Spring bölgesinden toplanmıştır. Güneş enerji santralinin çıkış gücü ilk olarak Ampirik mod ayrıştırma yöntemi ile bileşenlerine ayrılmıştır. Bu bileşenler ve diğer meteorolojik verilerden 1-3 saat ilerisi için tahmin çalışmaları gerçekleştirilmiştir. Bu çalışmanın diğer kısımları ise şu şekilde kısaca özetlenebilir. 2. kısımda makine öğrenme yöntemlerine ait genel bilgiler verilmiştir. 3. kısımda Ampirik mod ayrıştırma yöntemi sunulmuştur. Performans değerlendirme kriterileri ise 4. kısımda verilmiştir. 5. kısımda tüm makine öğrenme yöntemleri için deneysel çalışmalar gerçekleştirilmiştir. Son kısımda ise elde edilen sonuçlar değerlendirilmiştir.

## 2. Makine Öğrenme Yöntemleri

### 2.1. Doğrusal regresyon

Doğrusal Regresyon (DR) yöntemi bağımsız değişken (X) ile bağımlı değişken (Y) arasındaki doğrusal ilişkiyi ortaya koymaktadır. Ayrıca bu yöntem bağımsız ve bağımlı değişkenlerin ilişkisinin yönünü de pozitif veya negatif olarak belirtmektedir. Bu model çıkış olarak değişkenler arasındaki ilişkiyi kullanarak belirlenen zaman ufku tahmin sonucu vermektedir.[16]. Bağımsız değişkenin değeri bilindiği takdirde bağımlı değişkenin değeri aşağıdaki denklemde gösterildiği gibi belirlenebilir:

$$f(x) = ax + b \quad (1)$$

$$a = \frac{\sum_{i=1}^n (x_i - \bar{x})(f(x_i) - f(\bar{x}))}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (2)$$

$$b = f(\bar{x}) - a\bar{x} \quad (3)$$

Burada,  $a$  regresyon katsayısını ifade eder.  $b$  ise sabit bir sayıdır.

### 2.2. Destek vektör makinesi

DVM, yapısal risk minimizasyonu ilkesi ve istatistiksel öğrenme teorisine dayanarak geliştirilmiş olan, regresyon problemlerinin çözülmesinde kullanılan makine öğrenmesi yöntemidir. DVM eğitim hatasını minimize etmek ve yapay zekada karşılaşılan yerel optimumun içine düşmekten kaçınmak için deneysel risk minimizasyonu prensibi yerine yapısal risk minimizasyonu prensibini kullanmaktadır[17]. Ayrıca bu makine öğrenmesi yöntemi eğitim verisini doğrusal olmayan bir şekilde düşük boyutlu düzlemde

yüksek boyutlu uzaya haritalayabilme olanağı sunmaktadır. DVM'nin yukarıda bahsedilen karakteristiklerine dayanarak geleneksel tahmin modellerinin eksiklik gösterdiği noktaların üstesinden etkili bir şekilde gelebildiğini söylemek mümkündür. Doğrusal olmayan regresyon modelleri arasında gösterilen DVM yöntemi durağan varsayımına gerek olmadan tahmin gerektiren problemlerin çözümünde esneklik sağlayabilmektedir[18]. DVM hata değerinin olması gereken maksimum değerini belirlemeye izin vermekte ve veri setine uygun olan en iyi modelin bulunmasına olanak sağlamaktadır. Aşağıda, DVM için genel bir ifade verilmiştir.

$$y_t = a + w_t x_t + \varepsilon_t = 1, \dots, T \quad (4)$$

Burada,  $y_i$  çıkışı (tahmin edilen değer),  $a$  sınırları çizilen kısmı,  $w_i$  ağırlığı,  $x_i$  girişi (tahmin edici veriler) ve  $\varepsilon_i$  hata terimini ifade eder. Karesel hataların toplamını DVM gibi doğrusal modeller yardımıyla en aza indirilebilmektedir.

$$\min \sum_{t=1}^T (y_t - a - w_t x_t)^2 \quad (5)$$

DVM hata büyüklüğünü belirleme konusunda esneklik sağlayabilmektedir. Amaç fonksiyonu aşağıdaki gibi tanımlanabilir:

$$\min \frac{1}{2} \|w\|^2 \quad (6)$$

$$|y_t - a + w_t x_t| < \varepsilon_t \quad (7)$$

Amaç fonksiyonunu mümkün olduğunca minimize etmek için sapmaları da ilgili denkleme ekleyerek aşağıdaki formül elde edilebilir.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{t=1}^T |\xi_t| \quad (8)$$

$$|y_t - a + w_t x_t| < \varepsilon + |\xi_t| \quad (9)$$

Doğrusal olmayan DVM için kullanılan fonksiyon olan radyal kernel fonksiyonu yaygın olarak şu şekilde ifade edilir:

$$\exp\left(-\frac{\gamma}{2} \|x_t - x_t\|^2\right) \quad (10)$$

Burada,  $\gamma$  verideki değişikliği kontrol eden hassas bir parametredir.

### 2.3. Karar ağacı regresyonu

Karar ağacı regresyonu (KAR) makine öğrenmesinde ve görüntü işlemede yaygın olarak kullanılan metodların başında gelmektedir. KAR'ın anlaşılabilir konfigürasyon sağlamasından dolayı kullanıcıya kolaylık sağladığı bilinmektedir. KAR değişkenler arasındaki bağlantıyı göstermek için basit grafik yapılarını bünyesinde bulundurur. Bu özellik ise diğer makine öğrenme metodlarından birisi olan yapay sinir ağlarının belirsiz içyapısı ve sonuçlarının grafiğe dökülebilmesi yönüyle karşılaştırıldığında KAR'ın daha avantajlı olduğunu göstermektedir. Kavramsal kurallar YSA'daki gibi sayısal ağırlıklar olmadığından daha kolay bir şekilde inşa edilir. KAR yapısı düğümler ve dallardan oluşan bir ağaç modeline benzetilebilir. Her bir düğüm sınıflandırılacak kategorinin içindeki bir özelliği temsil ederken her bir alt bileşen de düğümün alabileceği değeri tanımlar [19-20].

### 2.4. Topluluk regresyonu

Topluluk regresyonu (TR), çoklu karar ağaçlarının toplanmasıyla tahmin performansı bakımından güçlü hale getirilmiş olan makine öğrenmesi tabanlı regresyon modelidir. Bu model zayıf öğrencilerin tahmin çıkışlarını toplayarak tahmin yapmaktadır. Algoritmanın çalışma hızı ve güvenilir sonuç vermesi göz önünde bulundurularak zayıf öğrencilerin sayısı deneysel olarak belirlenir[21].

### 2.5. Gauss süreç regresyonu

Gauss süreci regresyonu (GSR), esnek regresyon modelleri ve sınıflandırma için başlangıç dağılımını tanımlamak amacıyla kullanılan etkin bir yöntemdir [22]. GSR'nin en önemli özelliklerinden biriyse araştırmacılara farklı derecelerde fonksiyon oluşturabilme özelliği sağlayarak en doğru seçeneği belirlemesine imkân veren kovaryans fonksiyonlarının çeşitliliğine sahip olmasıdır. Birçok mühendislik probleminin çözülmesinde kullanılan regresyon süreci, olası parametrik olmayan modelleme metotları sağlamaktadır. Gauss süreci, gauss dağılımının genelleştirilmiş halidir. Gauss dağıtımı rastgele değişimler arasındaki yayılımı iken Gauss süreci fonksiyonlar arasındaki dağıtım olarak açıklanır. Gauss süreç fonksiyonu olan  $f(x)$  kovaryans ve ortalama  $m(x)$  fonksiyonu ile tanımlanır. Aralarındaki matematiksel ilişki aşağıdaki denklem ile ifade edilebilir.

$$m(x) = E(f(x)) \quad (11)$$

$$k(x, x') = E((f(x) - m(x))(f(x') - m(x')))) \quad (12)$$

Burada,  $k(x, x')$  kernel veya kovaryans fonksiyonunu ifade eder.  $f(x)$  fonksiyonu ise şu şekilde tanımlanabilir:

$$f(x) = GP(m(x), k(x, x')) \quad (13)$$

Genellikle basitleştirme amacıyla ortalama fonksiyon değeri sıfır olarak kabul edilir. Gauss sürecinde giriş vektörü ile amaç vektörü arasındaki ilişki şu şekildedir:

$$y_i = f(x_i) + \varepsilon \quad (14)$$

Burada,  $f(x)$  ve  $\varepsilon$  sırasıyla regresyon fonksiyonunu ve gauss dağılımının gürültü değerini ifade etmektedir. Ayrıca, kovaryans matrisi aşağıdaki gibi verilebilir.


$$k_{i,j} = k(x_i, x_j) \quad (15)$$

$$k = \begin{bmatrix} k(x_1, x_1) & \dots & k(x_1, x_n) \\ \vdots & \ddots & \vdots \\ k(x_n, x_1) & \dots & k(x_n, x_n) \end{bmatrix} \quad (16)$$

Burada,  $k_i$  gizli fonksiyonlar olan  $f(x_i)$  ve  $f(x_j)$  değerleri arasında belirlenen kovaryanstır.

### 3. Ampirik Mod Ayırıştırıcı

Ampirik mod ayırıştırıcının temel kullanım amacı, yerel karakteristik zaman serilerine dayalı içsel salınım fonksiyonlarını belirlemektir [23]. Aşağıdaki formülde görüldüğü üzere bu yöntem, orijinal zaman serisini bir dizi içsel mod işlevine (İMİ) ve kalana dönüştürmektedir. Matematiksel olarak şu şekilde ifade edilebilir:



Şekil 1: Ampirik mod ayrıştırımından elde edilen içsel mod işlevleri

$$x(t) = \sum_{j=1}^a \text{İMİ}_j(t) + r_a(t) \quad (17)$$

Burada, “ $x(t)$ ” orijinal zaman serisini, “ $j$ ” İMİ sayısını ve “ $r(t)$ ” ise kalan kısmı ifade etmektedir. Ampirik mod ayrıştırımı algoritması şu şekilde ifade edilebilir: İlk olarak verilen zaman serisinin maksimum ve minimum noktaları belirlenir. Daha sonra üst  $u(t)$  ve alt bürüm  $l(t)$ ’yi elde etmek için kübik bağlayıcı algoritması kullanılır. Daha sonra ise  $u(t)$  ve  $l(t)$ ’nin ortalaması alınarak  $m(t)$  elde edilir. Bu adımdan sonra ilk bileşen hesaplanır,  $h(t) = x(t) - m(t)$ . Eğer  $m(t)$ ’nin sifra yakın olması ve sifirgeçiş nokta sayısı ile yerel ekstrem nokta sayısı arasındaki fark en fazla bir olması şartları sağlanırsa  $h(t)$  bir İMİ gibi düşünülebilir. Aksi halde yapılan işlemler ilk adımdan başlanarak  $h(t)$  için tekrar edilir. Bu adımların ardından, ilk İMİ  $h(t)$ ’ye eşittir ve sonra ilk artık bileşen hesaplanır.  $r_1(t) = x(t) - h(t)$ . Diğer  $\text{İMİ}_{j+1}(t)$  ve  $r_{j+1}(t)$  değerlerini elde etmek için ise yine ilk adımdan itibaren uygulanan işlemler  $r_j(t)$ ’ye uygulanır. Eğer  $r_{j+1}(t)$ ’deki ekstrem nokta sayısı ikiden küçük veya eşit olursa algoritma sona erdirilir. Ampirik mod ayrıştırma yöntemi sonrası güneş santralinden elde edilen güç örneği Şekil 1’deki gibi elde edilir.

#### 4. Performans Değerlendirme Kriterleri

Bu bölümde, önerilen modelin diğer makine öğrenmesi metodları ile nicel performansını karşılaştırmak için kullanılan değerlendirme kriterleri anlatılmaktadır. Çalışmada, Korelasyon Katsayısı (R), Ortalama Karesel Hata (RMSE) ve Ortalama Mutlak Hata (MAE) olmak üzere üç tane performans değerlendirme kriteri belirlenmiştir. R, giriş ve çıkış parametrelerinin ne kadar bağlantılı olduğunu belirtir. RMSE ise tahmin hatasının standart sapması olarak tanımlanabilir. MAE ise tahmindeki hataların ortalama büyüklüğünü verir [24]. Bu bölümde bahsedilen değerlendirme metriklerinin her biri farklı bir değerlendirme olanağı sağladığı için makine öğrenme yöntemlerinden farklı zaman ufuklarında elde edilen tahmin performans sonuçları detaylı olarak incelenebilmektedir. Yukarıda bahsedilen performans değerlendirme kriterleri matematiksel olarak aşağıdaki gibi ifade edilebilir:

$$R = \frac{\sum_{i=1}^N [(P_i^f - \bar{P}^f) - (P_i - \bar{P})]}{\sqrt{\sum_{i=1}^N (P_i^f - \bar{P}^f)^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \quad (18)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i^f - P_i)^2} \quad (19)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i^f - P_i| \quad (20)$$

Burada,  $P_i$ , santralin gerçek (ölçülen) çıkış gücünü verirken,  $P_i^f$  tahmin metodlarından elde edilen çıkış gücünü ifade etmektedir.  $\bar{P}^f$  ve  $\bar{P}$  sırasıyla gerçek ve tahmin edilen gücün ortalamasıdır.

#### 5. Deneysel Çalışmalar

Bu kısımda, Avustralya, Alice Springs’de bulunan bir güneş enerji merkezindeki 1B: Trina isimli santralden [25] elde edilen elektrik enerjisinin kısa dönem tahmini için farklı makine öğrenmesi yöntemlerinin performansları incelenmiştir. Şekil 2’de Alice Springs’e ait genel yapı verilmiştir. Şekilden de görüleceği üzere bölgede birçok santral mevcuttur.




Şekil 2: Alice Springs’in genel gösterimi

Çalışmada kullanılan yöntemlere ait parametreler ise Tablo 1’de verilmiştir. Bu santralden toplanan veri seti 2017 yılına aittir ve saatlik aktif güç, bağıl nem, radyasyon ve sıcaklık gibi meteorolojik ölçümlerden oluşmaktadır. Elde edilen veri seti Şekil 3’te gösterilmiştir.



Tablo 1: Çalışma kullanılan yöntemlere ait parametreler

Parametre	DR	DVM	KAR	TR	GSR
Yaprak sayısı	-	-	4	4	-
Öğrenme sayısı	-	-	-	25	-
Dayanıklılık seçeneği	off	-	-	-	-
Fonksiyon ve aralığı	-	Kernel 0.60	-	-	Rasyonel Kuadratik otomatik



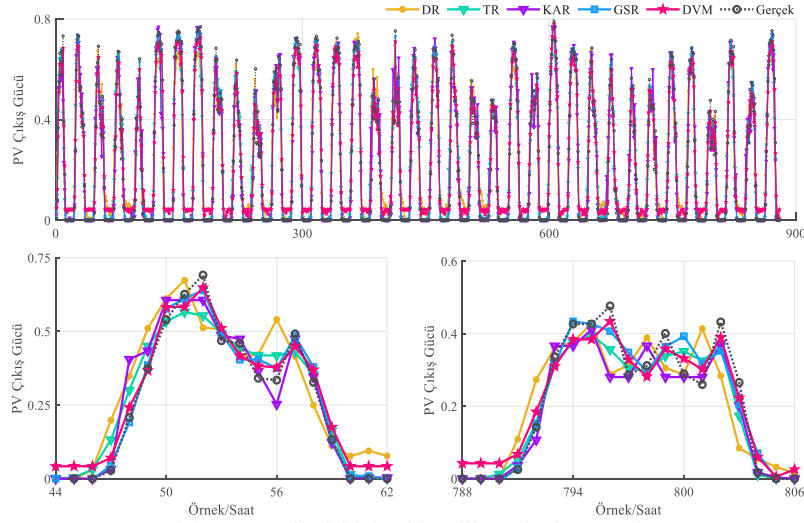
Şekil 3: 2017 yılına ait veri seti

Ayrıca, veri seti bir günün tüm saatlerini içerdiği için her bir meteorolojik ölçümler ve aktif güç için 8760 örnek kaydedilmektedir. Avustralya'da Kış; Haziran-Temmuz-Ağustos, İlkbahar; Eylül-Ekim-Kasım Sonbahar; Mart-Nisan-Mayıs ve Yaz ise Aralık-Ocak-Şubat aylarından oluşmaktadır. Güç örnekleri Ampirik mod ile bileşenlerine ayrıştırıldıktan sonra tüm veri seti 113,880 örnekten oluşmaktadır.


Veri setinde bulunan ölçüm değerlerinin minimum (Min), maksimum (Mak), medyan (Med), ortalama (Ort), standart sapma (Std) gibi istatistiksel özellikleri Tablo 2'de sunulmuştur.

Tablo 2: Veri setine ait istatistiksel özellikleri

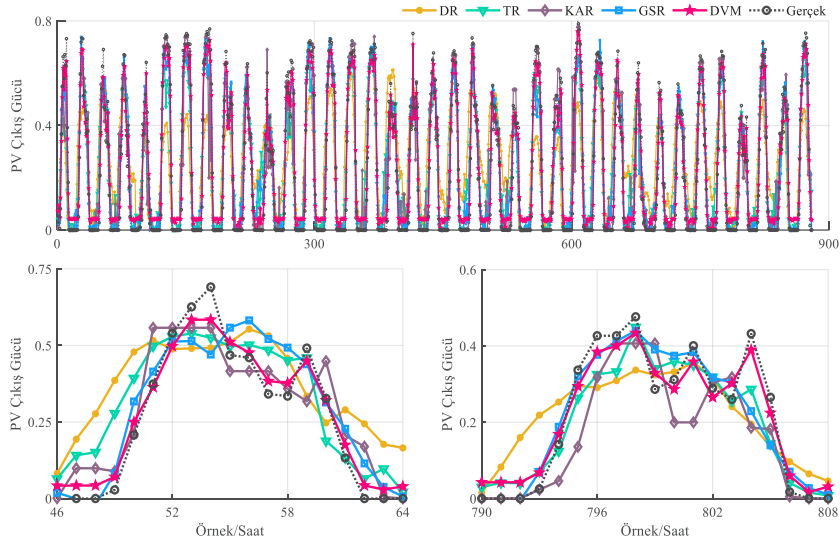
Değişken	Güç (kW)	Sıcaklık (°C)	Nem (%)	Radyasyon (Wh/m <sup>2</sup> )
Min	0	-3.24	4.32	1.31
Mak	20.49	43.14	101.70	1226.90
Med	0.274	22.53	29.52	11.92
Ort	5.26	21.95	34.74	267.34
Std	6.46	9.40	20.82	356.81



Şekil 4: 1-saat ilerisi için elde edilen tahmin sonuçları



Şekil 5: 2-saat ilerisi için elde edilen tahmin sonuçları



Şekil 6: 3-saat ilerisi için elde edilen tahmin sonuçları

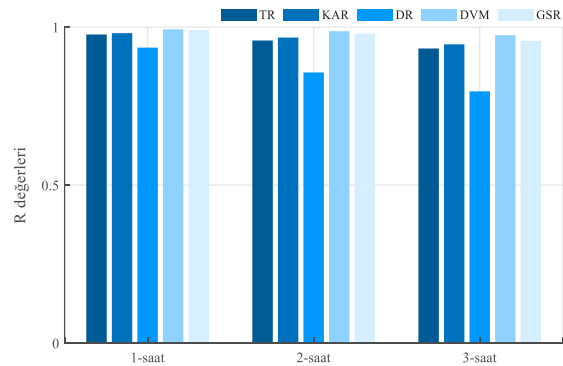
Daha sonra tahmin yöntemleri için eğitim, doğrulama ve test verileri hazırlanmıştır. Veri setinin %80'i eğitim için kullanılırken %10'u doğrulama ve %10'u da test için seçilmiştir. Eğitim boyunca seçilen veriler rastgele olacak şekilde tahmin yöntemlerine giriş olarak uygulanmıştır. En sık kullanılan makine öğrenme yöntemlerinden olan DR, DVM, KAR, TR ve GSR'nin güneş enerjisinin tahminindeki performansları farklı tahmin ufuklarında incelenmiştir. 1, 2 ve 3-saat ilerisi için tüm makine öğrenmesi yöntemlerinden elde edilen metrik sonuçları Tablo 3'te verilmiştir. Ayrıca, tahmin ufuklarından elde edilen sonuçlar Şekil 4, 5 ve 6'da detaylıca verilmiştir.

Tablo 3'teki metrik değerleri analiz edildiğinde tüm tahmin ufuklarında DVM'nin daha iyi sonuçlara sahip olduğu gözlemlenebilir. Ayrıca, tüm makine öğrenme yöntemlerinden elde edilen R değerlerinin daha iyi incelenebilmesi için Şekil 7 verilmiştir. R değerleri incelendiğinde DVM'nin değerleri 1-saat ilerisi için 0.9932, 2-saat ilerisi için 0.9871 ve 3-saat ilerisi için 0.9744 olarak hesaplanmıştır. En iyi ikinci R değerlerini ise 1-saat ilerisi için 0.9908, 2-saat ilerisi için 0.9795 ve 3-saat ilerisi için 0.9568 ile GSR sağlamıştır. En kötü R değerlerini ise 0.9351-0.8565-0.7967 değerleri ile DR göstermiştir. Elde edilen tüm R sonuçlarından, DVM'nin daha iyi ve güvenilir tahmin sonucu sağlayacağı açık bir şekilde ifade edilebilir.


Diğer metrik RMSE için elde edilen değerler tüm tahmin ufukları için değerlendirildiğinde yine DVM'nin daha tatmin edici tahmin sonuçlarını sağladığı görülmektedir. RMSE değerlerinin daha iyi gözlemlenebilmesi için Şekil 8'deki grafik verilmiştir. 1, 2 ve 3-saat ilerisi için DVM'nin RMSE değerleri sırasıyla 0.0244, 0.0381 ve 0.0428 olarak hesaplanmıştır. GSR için RMSE değerleri 0.0388-0.0481-0.0712 olarak hesaplanmıştır. En kötü sonuçları ise yine DR, 1-saat ilerisi için 0.0946, 2-saat ilerisi için 0.1462 ve 3-saat ilerisi için 0.1834 değerleri ile vermiştir. Bu performans metriği sonuçları değerlendirildiğinde tahmin ufukunun değişimine karşı en kararlı sonuçları DVM sağlamıştır. Bu değerlerden DVM'nin uzun tahmin ufuklarında bile güvenilir tahmin sonuçlarını garanti edeceği anlaşılabilir.

Tablo 3: Tahmin ufuklarından elde edilen metrik sonuçları

Tahmin Ufku	Yöntem	Performans Metriği		
		R	RMSE	MAE
1-saat	TR	0.9767	0.0582	0.0344
	KAR	0.9811	0.0517	0.0272
	DR	0.9351	0.0946	0.0694
	DVM	0.9932	0.0244	0.0154
	GSR	0.9908	0.0388	0.0257
2-saat	TR	0.9577	0.0797	0.0527
	KAR	0.9671	0.0679	0.0386
	DR	0.8565	0.1462	0.1138
	DVM	0.9871	0.0381	0.0255
	GSR	0.9795	0.0481	0.0392
3-saat	TR	0.9324	0.0960	0.0707
	KAR	0.9455	0.0869	0.0488
	DR	0.7967	0.1834	0.1490
	DVM	0.9744	0.0428	0.0371
	GSR	0.9568	0.0712	0.0463




Şekil 7: Tüm tahmin ufuklarından elde edilen R değerleri



Şekil 8: Tüm tahmin ufuklarından elde edilen RMSE değerleri

Tüm makine öğrenme yöntemleri MAE değerleri açısından incelendiğinde yine en iyi değerlere DVM sahiptir. En küçük MAE değerleri ile daha az hata olduğu anlaşılabilmektedir. MAE değerlerinin daha iyi analizi için Şekil 9'daki grafik eklenmiştir. DVM'nin MAE değerleri 1-saat ilerisi için 0.0154, 2-saat ilerisi için 0.0255 ve 3-saat ilerisi için 0.0371 olarak hesaplanmıştır. DVM'yi yine en iyi ikinci performansa sahip olan GSR takip etmiştir. En kötü MAE değerlerine ise 1-saat ilerisi için 0.0694, 2-saat ilerisi için 0.1138 ve 3-saat ilerisi için 0.1490 ile DR vermiştir. Elde edilen MAE değerlerin incelendiğinde DVM'nin güvenilir tahmin sonuçlarını artan zaman ufkuna rağmen tatmin edici bir şekilde sağladığı görülmektedir.



Şekil 9: Tüm tahmin ufuklarından elde edilen MAE değerleri

## 6. Sonuçlar

Günümüz tüketim toplumunda enerji ihtiyacı her geçen gün büyüyerek artmaktadır. Enerjiye ihtiyaç artarken, enerji üretmek için kullanılan kaynaklar da günden güne azalmaktadır. Yenilenebilir enerji kaynaklarının giderek azalması ile yenilenebilir enerji kaynaklarına yönelimde bir hayli artmış durumdadır. Bu sebeple makine öğrenmesi metotlarının kullanılmasıyla Güneş'ten elde edilen elektrik enerjisinin tahmini ve bu doğrultuda enerji planı oluşturmak büyük bir önem taşır hale gelmiştir. Bu çalışmada, Avustralya, Alice Springs'de bulunan bir güneş enerji merkezindeki 1B:Trina isimli santralden elde edilen veri seti kullanılarak farklı regresyon yöntemlerinin tahmin performansları detaylı bir şekilde analiz edilmiştir. Bu amaç için sıklıkla kullanılan DR, DVM, KAR, TR ve GSR gibi makine öğrenmesi metotları tercih edilmiştir. Bu metotlardan elde edilen tahmin cevaplarını değerlendirmek için R, RMSE ve MAE gibi performans metrikleri kullanılmıştır. Ayrıca, tahmin ufkunun değişimine karşı makine öğrenmesi metotlarının dayanıklılığı ve

güvenilirliği analiz edilmiştir. Bu amaç için tahmin ufku 1 ila 3 saat sonrası olarak seçilmiştir. Tüm tahmin ufuklarından elde edilen metrik sonuçları için en iyi tahmin performansını DVM sağlamıştır. DVM'yi sırasıyla GSR, KAR, TR ve DR takip etmiştir. İleriki çalışmalarda ise farklı ayırıştırma yöntemlerinin tahmin performansı üzerine olan etkileri araştırılacaktır. Ayrıca, daha fazla meteorolojik verilerin elde edilmesi ile daha doğru tahmin sonuçlarının sağlanabilmesi hedeflenmektedir.


## 7. Kaynakça

- [1] Ahmed, R., Sreeram, V., Mishra, Y., Arif, M.D. "A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization", *Renewable and Sustainable Energy Reviews*, 124, pp. 1-26, 2020.
- [2] Akhter, M.N., Saad, M., Hazlie, M., Noraisyah, M. S. "Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques", *IET Renewable Power Generation*, 13(7), pp. 1009-1023, 2019.
- [3] Kim, S., Jung, J., Sim, M. "A two-step approach to solar power generation prediction based on weather data using machine learning", *Sustainability*, 2019.
- [4] Sobri, S., Koohi-Kamali, S., Rahim, N. "Solar photovoltaic generation forecasting methods: a review", *Energy Conversion and Management*, 156 pp. 459-97, 2017.
- [5] Raza, M., Q., M. Nadarajah, C. Ekanayake. "On recent advances in PV output power forecast", *Solar Energy*, 136, pp.125-144, 2016.
- [6] Şahan, M., Okur, Y. "Akdeniz bölgesine ait meteorolojik veriler kullanılarak yapay sinir ağları yardımıyla güneş enerjisinin tahmini", *Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Fen Dergisi*, 11(1), ss. 61-71, 2016.
- [7] Demolli, H., Dokuz, A. Ş., Gokcek, M., Ecemiş, A. "Makine Öğrenmesi Algoritmalarıyla Güneş Enerjisi Tahmini: Niğde İli Örneği", *International Turkic World Congress on Science and Engineering*, ss. 775-783, 2019.
- [8] Gök, A.O., Yıldız, C., Şekkel M. "Yapay sinir ağları kullanarak kısa dönem güneş enerjisi santrali üretim tahmini: Kahramanmaraş örnek çalışması", *Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi*, 1(2), ss.186-195, 2019.
- [9] Wolff, B., Kühnert, J., Lorenz, E., Kramer, O., Heinemann, D. "Comparing support vector regression for PV power forecasting to a physical modeling approach using measurement, numerical weather prediction, and cloud motion data", *Solar Energy*, 135, ss. 197-208, 2016.
- [10] Mahmud, K., Azam, S., Karim, A., Zobaed, S. "Machine learning based pv power generation forecasting in alice springs", *IEEE Access*, pp. 1-13, 2021.

- [11] Massaoudi, M., Chihi I., Sidhom L., Trabelsi M., Refaat, S., Abu-Rub, H. “ An effective hybrid narx- lstm model for point and interval pv power forecasting”, *IEEE Access*, 9, pp. 36571-36588, 2021.
- [12] Korkmaz, D., Açıkğöz, H., Yıldız C. “A novel short-term photovoltaic power forecasting approach based on deep convolutional neural network”, *Int J Green Energy*, 18, pp. 1–15, 2021.
- [13] Yıldız, C., Açıkğöz, H. “A kernel extreme learning machine-based neural network to forecast very short-term power output of an on-grid photovoltaic power plant”, *Energy Sources Part A: Recovery, Utilization and Environmental Effects*, 43(4), pp. 395–412, 2021.
- [14] Uğuz, S., Oral, O., Çağlayan, N. “PV Güç Santrallerinden Elde Edilecek Enerjinin Makine Öğrenmesi Metotları Kullanılarak Tahmin Edilmesi”, *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 11(3), ss.769-779,2019.
- [15] Özdemir, M.H., İnce, M., Aylak, B.L., Oral, O., Taş, M.A. “Installed Solar Power Prediction For Turkey Using Artificial Neural Network And Bidirectional Long Short-Term Memory”, *Business & Management Studies: An International Journal*, 8(5), pp. 4047-4068, 2020
- [16] Yulita, I. N., Abdullah, A. S., Helen, A., Hadi, S., Sholahuddin, A., Rejito J. “Comparison multi-layer perceptron and linear regression for time series prediction of novel coronavirus covid-19 data in West Java”, *Journal of Physics: Conference Series*, 1722, pp. 1-8, 2021.
- [17] Abdullah, A. S., Ruchjana, B. N., Jaya, M., Soemartini. “Comparison of sarima and svm model for rainfall forecasting in bogor city indonesia” *Journal of Physics: Conference Series*, 1722, pp. 1-8, 2020.
- [18] Guo, W., Che, L., Shahidehpour, M., Wan X. “Machine-Learning based methods in short-term load forecasting”, *The Electricity Journal*, 34, 2021.
- [19] Jijo, B. T., Abdulazeez, A. M. “Classification based on decision tree algorithm for machine learning”, *Journal Of Applied Science And Technology Trends*, 2(1), pp. 20-28, 2021.
- [20] Murlidhar, B. R., Bejarbaneh, B. Y., Armaghani D. J., Mohammed A. S., Mohamad E. T. “Application of tree-based predictive models to forecast air overpressure induced by mine blasting”, *Natural Resources Research*, 30(2), 2021.
- [21] Saha, M., Santara, A., Mitra, P., Chakraborty, A. Nanjundiah R S. “Prediction of the indian summer monsoon using a stacked autoencoder and ensemble regression model”, *International Journal of Forecasting*, 37, pp. 58-71, 2021.
- [22] Ghasemi, P., Karbasi, M., Nouri, A. Z., Tabrizi, M. S., Azamathulla, H. M. “Application of gaussian process regression to forecast multi-step ahead SPEI drought index” *Alexandria Engineering Journal*, 60(6), pp. 5375–5392, 2021.
- [23] Qiu, X., Ren, Y., Suganthan, P. N., Amaratunga, G. “Empirical Mode decomposition based ensemble deep learning for load demand time series forecasting”, *Applied Soft Computing Journal*, 54, pp. 246–55, 2017.
- [24] Acikgoz, H., Budak, U., Korkmaz, D., Yildiz, C. “WSFNet: An efficient wind speed forecasting model using channel attention-based densely connected convolutional neural network”, *Energy*, 233, pp. 1-16, 2021.
- [25] DKASC. Alice Springs, 1B: Trina 2020. <http://dkasolarcentre.com.au/source/alice-springs/dka-m9-a-c-phases>



## Özgeçmişler



**M. Fatih BEKÇİOĞULLARI**, Lisans eğitimini 2019 yılında Kahramanmaraş Sütçü İmam Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. 2020 yılında aynı üniversitenin Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilimdalı'nda yüksek lisans eğitimine başlamıştır. 2021 yılında Gaziantep İslam Bilim ve Teknoloji Üniversitesi'nde Araştırma Görevlisi olarak çalışmaya başlamıştır. Araştırma alanları derin öğrenme, makine öğrenmesi ve enerji tahminidir.

---



**Bünyamin DİKİCİ**, 2021' de Gaziantep Üniversitesi Elektrik Elektronik Mühendisliği Bölümün' de yüksek lisans eğitimini tamamlamıştır. Aynı yıl içerisinde yine aynı okul ve bölümde doktora eğitimine başlamıştır. 2019 yılından beri Araştırma görevlisi olarak Gaziantep İslam Bilim ve Teknoloji Üniversitesin' de Elektrik-Elektronik Mühendisliği Bölümünde görev yapmaktadır. Araştırma alanları yapay zeka, derin öğrenme, sınıflandırma, tahmin ve haberleşmedir.

---



**Hakan AÇIKGÖZ**, Kahramanmaraş doğumludur. Lisans ve Yüksek Lisans eğitimini sırasıyla 2008 ve 2010 yıllarında Fırat Üniversitesinde tamamlamıştır. 2013-2018 yılları arasında, Kahramanmaraş Sütçü İmam Üniversitesi Elektrik-Elektronik Mühendisliği alanında doktora çalışmasını tamamlamıştır. 2010-2012 yılları arasında Batman Üniversitesi Mekatronik Mühendisliği bölümünde Araştırma Görevlisi olarak çalışmıştır. 2013-2019 yılları arasında ise Kilis 7 Aralık Üniversitesi Elektrik-Enerji bölümünde Öğretim Görevlisi olarak çalışmıştır. 2020 yılından itibaren ise Gaziantep İslam Bilim Ve Teknoloji Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Bölümünde Öğretim Üyesi olarak çalışmaya devam etmektedir. Araştırma alanları güç dönüştürücülerinin denetimi, optimizasyon, yapay zekâ ve makine öğrenmesidir.

---



**Ö. Fatih KEÇECİÖĞLÜ**, Lisans, Yüksek Lisans ve Doktora Eğitimlerini sırasıyla 2010, 2012 ve 2017 yıllarında Kahramanmaraş Sütçü İmam Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde tamamlamıştır. 2011-2017 yılları arasında Kahramanmaraş Sütçü İmam Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde Araştırma Görevlisi olarak çalışmıştır. 2017-2021 yılları arasında aynı bölümde Dr. Öğr. Üyesi olarak çalışmıştır. 2021 yılından itibaren ise Elektrik-Elektronik Mühendisliği bölümünde Doçent olarak görev yapmaktadır. Araştırma alanları güç kalitesi, harmonik filtreler, güç elektroniği, reaktif güç kompanzasyonu ve yenilenebilir enerji sistemleridir.

---