



Uydu Verileri ile Güneş Işınımı Tahmininde Farklı Makine Öğrenmesi Yöntemlerinin Kullanımı

İlayda PALA¹, Abdülkadir KOÇER^{2*}

¹ Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Yenilenebilir Enerji Teknolojileri Anabilim dalı, 07070 ANTALYA

² Akdeniz Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, 07070, ANTALYA

Makale Bilgisi

Araştırma makalesi
Başvuru: 30/05/2025
Düzeltilme: 28/07/2025
Kabul: 12/08/2025

Anahtar Kelimeler

Makine öğrenmesi
Güneş enerjisi
Rastgele orman
XGBoost

Article Info


Research article
Received: 30/05/2025
Revision: 28/07/2025
Accepted: 12/08/2025

Keywords

Machine learning
Solar energy
Random forest
XGBoost

Grafik Özet (Graphical/Tabular Abstract)

Güneş enerjisi sistemlerinin tasarımında güneş ışınımının doğru tahmini önemlidir. Bu çalışmada, Afyonkarahisar ve Elazığ illerine ait 2000-2024 arası 18.264 günlük veriyle güneş ışınımı tahmini yapılmış, MLR, SVR, XGB ve RF algoritmaları karşılaştırılmıştır. / Accurate prediction of solar radiation is crucial for designing solar energy systems. In this study, 18,264 daily meteorological records (2000-2024) from Afyonkarahisar and Elazığ were used to estimate solar radiation. MLR, SVR, XGB, and RF algorithms were applied and compared for prediction performance.



Şekil A: Güneş Işınımı Tahmin Süreci / Figure A: Solar Radiation Prediction Process

Önemli noktalar (Highlights)

- 18.264 gözlem içeren Afyonkarahisar ve Elazığ'a ait günlük meteorolojik verilerle modelleme yapılmıştır. / Modeling was conducted using 18,264 daily meteorological observations from Afyonkarahisar and Elazığ.
- Güneş ışınım tahmini için MLR, SVR, XGBoost ve RF algoritmaları kullanılmıştır. / MLR, SVR, XGBoost, and RF algorithms were used for solar radiation prediction.
- R², RMSE, MSE, MAE ve MAPE metrikleri ile model karşılaştırması yapılmıştır. / Model performance was evaluated using R², RMSE, MSE, MAE, and MAPE metrics.
- 10 katlı çapraz doğrulama ile modellerin genellenebilirliği artırılmıştır. / 10-fold cross-validation was applied to improve model generalizability.

Amaç(Aim): 2000-2024 yılları arasında Afyonkarahisar ve Elazığ'a ait günlük meteorolojik verilerle (sıcaklık, nem, rüzgar hızı, basınç) güneş ışınımını dört makine öğrenmesi modeli (MLR, SVR, XGB, RF) ile tahmin etmektir. Modeller, R², RMSE, MSE, MAE ve MAPE ile değerlendirilmiştir. / To predict solar radiation using daily meteorological data (temperature, humidity, wind speed, pressure) from Afyonkarahisar and Elazığ between 2000 and 2024 with four machine learning models (MLR, SVR, XGB, RF). The models were evaluated using R², RMSE, MSE, MAE, and MAPE metrics.

Özgünlük (Originality): Türkiye'nin farklı iklim bölgelerine ait uzun dönemli verilerle yapılan bu analiz, güneş ışınım tahmininde makine öğrenmesi yöntemlerinin güvenilirliğini ortaya koymaktadır. Literatürde bu ölçekte az sayıda çalışma bulunması, araştırmayı özgün kılmaktadır. / This analysis, conducted using long-term data from different climatic regions of Turkey, demonstrates the reliability of machine learning methods in solar radiation prediction. The limited number of studies at this scale in the literature highlights the originality of this research.

Bulgular (Results): Afyonkarahisar için R²=0.9866, MAE=0.19, MAPE=%6.12, RMSE=0.27 olarak Elazığ için R²=0.9887, MAE=0.19, MAPE=%6.51, RMSE=0.26 hesaplanmıştır. RF modeli farklı iklim koşullarında dahi tutarlı ve yüksek doğrulukla tahmin edilmiştir. / For Afyonkarahisar, R² was calculated as 0.9866, MAE as 0.19, MAPE as 6.12%, and RMSE as 0.27; for Elazığ, R² was 0.9887, MAE 0.19, MAPE 6.51%, and RMSE 0.26. The RF model provided consistent and highly accurate predictions even under different climatic conditions.

Sonuç (Conclusion): RF ve XGB modelleri güneş ışınımı tahmininde yüksek doğruluk ve genellenebilirlik sağlamış, enerji planlaması ve sürdürülebilirliğe katkıda bulunmuştur. / RF and XGB models achieved high accuracy and generalizability in solar radiation prediction, contributing to energy planning and sustainability.



Uydu Verileri ile Güneş Işınımı Tahmininde Farklı Makine Öğrenmesi Yöntemlerinin Kullanımı

İlayda PALA¹, Abdülkadir KOÇER^{2*}

¹ Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Yenilenebilir Enerji Teknolojileri Anabilim dalı, 07070 ANTALYA

² Akdeniz Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, 07070, ANTALYA

Makale Bilgisi

Araştırma makalesi
Başvuru: 30/05/2025
Düzeltilme: 28/07/2025
Kabul: 12/08/2025

Anahtar Kelimeler

Makine öğrenmesi
Güneş enerjisi
Rastgele orman
XGBoost

Öz

Güneş enerjisi ile yapılacak yatırımlarda en önemli parametrelerden birisi güneş ışınlamı miktarıdır. Güneş ışınlamını etkileyen birçok parametre vardır. Hava sıcaklığı, rüzgar hızı, bağıl nem ve basınç bu parametrelerin başında gelmektedir. Bu çalışmada, 2000-2024 yıllarını kapsayan Afyonkarahisar ve Elazığ illerine ait toplam 18 264 gözlemden oluşan bir veri seti kullanılarak farklı makine öğrenmesi algoritmaları ile güneş ışınlamı tahmini yapılmıştır. Çalışma kapsamında çoklu doğrusal regresyon ve Destek Vektör Regresyonu (SVR), XGBoost (XGB) ve Rastgele Orman (RF) gibi doğrusal olmayan makine öğrenmesi algoritmaları kullanılmıştır. Geliştirilen modellerin kalite performansları; belirlleme katsayısı (R^2) ve RMSE, MSE, MAE ve MAPE gibi hata metrikleri aracılığıyla belirlenmiştir. Çalışma sonucunda RF ve XGB modellerinin başarılı bir şekilde yüksek tahmin performansını sergiledikleri ortaya konulmuştur. Afyonkarahisar ve Elazığ illeri için en yüksek R^2 değeri sırasıyla 0.9866 ve 0.9887 ile RF algoritmasında elde edilmiştir.

The use of different machine learning methods in solar radiation estimation with satellite data

Article Info

Research article
Received: 30/05/2025
Revision: 28/07/2025
Accepted: 12/08/2025

Keywords

Machine learning
Solar energy
Random forest
XGBoost

Abstract

One of the most important parameters when investing in solar energy is the amount of solar radiation. There are many parameters that influence solar radiation. Air temperature, wind speed, relative humidity and pressure are the first of these parameters. In this study, sun radiation was estimated with different machine learning algorithms using a total dataset consisting of 18,264 observations of Afyonkarahisar and Elazığ provinces for the years 2000-2024. Non-linear regression and support vector regression (SVR), XGBoost (XGB) and random forest (RF) were used in the study. The quality performance of the developed models; the coefficient of determination (R^2) and RMSE, MSE, MAE and MAPE are determined by error metrics. As a result of the study, RF and XGB models have successfully achieved high estimation performance. The highest R^2 value for Afyonkarahisar and Elazığ provinces was obtained in the RF algorithm with 0.9866 and 0.9887 respectively.

1. GİRİŞ (INTRODUCTION)

Küresel enerji talebinin hızla artmasıyla, enerji kaynaklarına olan ihtiyaç büyümektedir. Enerjiye olan ihtiyaç elektrik talebi, sanayileşme, ulaşım da elektrik kullanımı ve yapay zekâ gibi teknolojilerin etkisiyle artmıştır. Bu enerji talebi yenilenebilir enerji kaynaklarının stratejik önemini ortaya koymuş olup; fosil yakıtlara olan bağımlılığı azaltmanın, iklim krizine karşı mücadelede ne kadar kritik olduğunu göstermektedir. Talebin büyük

bölümü güneş enerjisi başta olmak üzere düşük emisyonlu kaynaklardan karşılanmaktadır [1].

Güneş enerjisinin verimliliği, hava koşullarına bağlı olarak değişmektedir. Güneş ışınlamı; sıcaklık, bağıl nem, rüzgar hızı ve bulutluluk gibi meteorolojik faktörlere bağlıdır. Bu faktörler güneş enerjisinden enerji üretimini doğrudan ya da dolaylı yoldan etkilemektedir. Bu meteorolojik değişiklikler, güneş enerjisinin üretiminde ani dalgalanmalara yol açmakta ve bu nedenle sürekli bir enerji üretimi

sağlanamamaktadır. Ayrıca, güneş enerjisinin belirsiz yapısı ve gün içindeki hava koşullarına bağlı dalgalanmalardan dolayı, enerji şebekesinde ani gerilim düşüşlerine neden olabilmektedir. Kısa vadeli enerji tahminleri, enerji sistemlerinin istikrarı için önemli bir konu haline gelmiştir [2]. Son yıllarda, güneş enerjisi üretiminin tahmini konusunda pek çok araştırma ve çalışma gerçekleştirilmiştir. Bu alandaki literatür, özellikle güneş enerjisinin zaman içindeki değişkenliğini doğru bir şekilde öngörebilmek için çeşitli yöntemlerin ve modellerin geliştirilmesine odaklanmaktadır [3]. Ampirik modellere alternatif olarak makine öğrenimi modelleri, isabetli sonuçlar vermeleri nedeniyle güneş ışıınımı tahminleri için etkili bir yöntem olarak görülmektedir. Yaygın olarak tercih edilen yöntemler arasında yapay zekâ ve makine öğrenmesi uygulamaları yer almaktadır [4].

Makine öğrenmesi modelleri veri analizi ve tahminleme süreçlerinde geniş bir yelpazede kullanılmaktadır. Denetimli öğrenme, etiketli verilerle çalışarak sınıflandırma ve regresyon problemlerini çözmek için doğrusal regresyon, lojistik regresyon, karar ağaçları, destek vektör makineleri ve yapay sinir ağları gibi yöntemler kullanılmaktadır [5].

Yine diğer yöntemlerden biri olan Ansambl öğrenme (Ensemble Learning), birden fazla zayıf modeli bir araya getirerek daha güçlü ve doğru bir model elde etme yöntemidir. Bu yaklaşım, genellikle daha yüksek doğruluk ve genelleme yeteneği sağlamak amacıyla kullanılmaktadır. Ansambl öğrenme yöntemleri XGBoost (XGB), Random Forest (RF), LightGBM ve CatBoost modelleridir [6].

Villegas-Mier ve arkadaşları yaptığı bir çalışmada Juriquilla bölgesinde 2020 ve 2021 yıllarına ait verilerle güneş radyasyonunu tahmin etmek için RF, Adaboost, Basit Doğrusal Regresyon (SLR) ve Yapay Sinir Ağları (ANN, MLP) modellerini kullanarak farklı algoritmaların doğruluk oranlarını karşılaştırmış ve hiperparametre optimizasyonu ile özellikle RF ve Adaboost modellerinin %95.98'e varan yüksek doğrulukla en iyi performansı gösterdiğini ortaya koymuşlardır [7].

Ercan ve Koçer yaptıkları çalışmada, Akdeniz Bölgesi'ndeki 8 şehir için güneş ışıınımını tahmin etmek için Gradient Boosting (GB), XGB ve Yapay Sinir Ağları modellerini kullanarak en iyi sonucu XGB yöntemiyle elde etmişlerdir. Bu yöntemle en yüksek doğruluk oranı $R^2 = 0.9993$ ve düşük hata

değeri $MAPE = 0.0119$ olan sonuçları elde etmişlerdir[8].

Sezikli ve diğerleri; RF, Karar Ağaçları, K-En Yakın Komşu (KNN), Lasso Regresyonu, Ridge Regresyonu, Polinomial Regresyon ve Doğrusal Regresyon (LR) modellerini kullanarak güneş enerjisi panellerinden elde edilen verilerle modellerin performansını değerlendirmişlerdir. Random Forest algoritması ile en yüksek $R^2 = 0.9778$ skoru ile en başarılı sonuçları elde etmiştir[9].

Bamisile ve diğerleri, Afrikadaki bir lokasyonda 2016-2017 yıllarında Rotating Shadowband Işıınımölçer (RSI) cihazı ve Silikon piranometreyle, 1 dakikalık aralıklarla ölçülen güneş ışıınımı verilerini kullanarak güneş radyasyonu tahmini yapmışlardır. 566 251 veriden oluşan Global Yatay Işıınım (GHI) ve Dağılmış Işıınım (DHI) değerlerini kullanmışlardır. Yapılan çalışmada Long Short-Term Memory (LSTM), XGB, Çoklu Doğrusal Regresyon (MLR) ve Karar Ağacı Regresyonu (DTR) modellerinden XGB modeli, diğer modellere kıyasla daha iyi ve tutarlı sonuçlar vermiştir. GHI tahminlerinde $R^2 = 0.846$ aralığında, DHI tahminlerinde $R^2 = 0.779$ bulunmuştur [10].

Sagar ve diğerleri, güneş enerjisi sistemlerini optimize etmek için güneş radyasyonunu tahmin etmek amacıyla RF, XGB ve Çok Katmanlı Algılayıcı (MLP) modelinin doğruluğunu karşılaştırmışlardır. Çalışmada kullanılan veri seti, sıcaklık, nem, rüzgar hızı ve gün doğumu/batımı saatleri gibi meteorolojik ve zamanla ilgili özellikleri içermektedir. XGB modeli üstün bir performans sergileyerek $0.93 R^2$ ve $81.87 RMSE$ değerlerine ulaşmış, verilerdeki karmaşık doğrusal olmayan ilişkileri etkili bir şekilde yakalamıştır. MLP modelinin, R^2 değeri biraz daha düşük olmasına rağmen, en düşük ortalama mutlak hata $MAE = 41.74$ değerini göstermiştir [11].

Azam ve diğerleri, Ağustos 2020 - Temmuz 2023 tarihleri arasındaki 3 yıllık bir ölçüm süresi olan veri setini kullanarak Aylık ortalama dağınık güneş radyasyonunu tahmin etmek için makine öğrenmesi modelleri geliştirmişler ve bu modellerin başarıları bölgeye özgü en iyi dört deneysel modelle karşılaştırmışlardır. Destek Vektör Makineleri (SVM), Gauss Süreçleri Regresyonu (GPR), RF, KNN, MLP ve XGB modellerini kullanmışlardır. Her model R^2 , MAE, RMSE, MAPE gibi istatistiksel kriterlere göre değerlendirilmiş ve kriterler ölçeklendirilerek her modele Global Performans İndeksi (GPI) atanmıştır. Sonuç olarak

XGB modeli, en yüksek GPI skoru olan 6.073 ile en iyi performansı göstermiştir [12].

Wan ve diğerleri, yaptıkları çalışmada Chongqing bölgesinde güneş difüz radyasyonu tahmin etmek için yüksek hassasiyetli bir model geliştirmiştir. 8179 ölçüm verisi kullanılarak RF modeli ile tahminler yapılmış ve modelin doğruluğu, $R^2 = 0.72$, $MAE = 35.99$ ve $RMSE = 50.46$ gibi istatistiksel sonuçlarla değerlendirilmiştir [13].

Küçüktopçu ve diğerleri, Kütahya iline ait 1981-2010 yılları arasındaki meteorolojik veriler kullanarak günlük güneş radyasyonu tahmini için KNN, destek vektör regresyonu (SVR) ve RF modellerini değerlendirmiş ve bu modellerin dalgacık dönüşümü (WT) ile kombinasyonları da değerlendirilmiştir. Sonuçlar, SVR ve KNN modellerinin hem doğruluk hem de belirsizlik açısından benzer performanslar sergilediğini göstermektedir. Ancak, KNN-WT, RF-WT ve SVR-WT gibi hibrit modeller, bireysel ML modellerine göre daha yüksek doğruluk sağlamaktadır. Özellikle, SVR-WT modeli, güneşlenme süresi, hava sıcaklığı, rüzgar hızı ve bağıl nem gibi girdilerle en iyi performansı sergileyerek test verisi için $R^2 = 0.923$, $RMSE: 2.174$ MJ/m² değerlerini elde etmişlerdir[14].


Yuzer ve Bozkurt yaptıkları çalışmada Hakkari ilinde 2019-2021 yılları arasında 5 saniyelik aralıklarla toplanan yaklaşık bir milyon veri noktasını kullanarak, yapay sinir ağı (ANN) modelleriyle güneş ışıınımı tahmini gerçekleştirmiştir. Çalışmada beş farklı eğitim algoritması ve iki farklı ANN mimarisi denenmiş; gizli katmandaki nöron sayısının ve kullanılan transfer fonksiyonlarının tahmin doğruluğu üzerindeki etkileri analiz edilmiştir. En başarılı sonuç, Levenberg–Marquardt algoritması ve “tansig” transfer fonksiyonuna sahip, 100 nöronlu ağ yapısıyla elde edilmiş olup, modelin korelasyon katsayısı $R = 0.9783$ ve ortalama mutlak yüzde hatası (MAPE) %6.79 olarak elde etmişlerdir [15].

Bu çalışmanın amacı, Ocak 2000- Aralık 2024 yılları arasındaki Afyonkarahisar ve Elazığ şehirlerine ait günlük meteorolojik veriler kullanarak, güneş radyasyonunun tahmininde 4 farklı makine öğrenmesi modelinin (RF, XGB, SVR, MLR) performanslarını değerlendirmektir. Çalışmada, her bir modelin doğruluğu, hata metrikleri olan R^2 , RMSE, MSE, MAE ve MAPE ile değerlendirilmiş ve hangi modelin en iyi tahmin doğruluğunu sağladığı belirlenmiştir. Türkiye bağlamında NASA verisinin farklı iklim bölgelerinde modellenmesine yönelik çalışmaların

sınırlı olması, bu araştırmanın özgün yönlerinden biri olarak öne çıkmaktadır. Bu çalışma, güneş radyasyonunun doğru tahmin edilmesinin, güneş enerjisi sistemlerinin verimliliği ve optimizasyonu açısından önemli olduğunu vurgulamaktadır.

2. MATERYAL VE METOD (MATERIALS AND METHODS)

Bu çalışmada, güneş radyasyonu tahmini amacıyla çeşitli makine öğrenimi modelleri kullanılmıştır. İlk olarak, veriler toplanmış ve eksik ya da aykırı gözlemler veri ön işleme adımıyla düzeltilmiştir. Veriler normalize edilerek modellemeye hazır hale getirilmiştir. Modelleme aşamasında SVR, RF, XGB, MLR algoritmaları uygulanmıştır. Bazı modellerde hiperparametre optimizasyonu yapılmıştır. Çalışmanın genel akışını ve izlenen yöntem adımlarını özetleyen şematik gösterim Şekil 1'de sunulmuştur.



Şekil 1. Çalışmanın Akış Şeması (Flow Chart of the Study)

2.1. Veri Toplama (Data Collection)

Güneş Enerjisi Potansiyel Atlası (GEPA) verilerine göre, Türkiye'deki yıllık ortalama güneşlenme süresi 2.741 saat olarak belirlenmiştir; bu da günlük yaklaşık 7.5 saatlık bir süreye denk gelmektedir. Ayrıca, ülkedeki toplam güneş enerjisi ışıınım miktarı yıllık 1.527 kWh/m² olarak hesaplanırken, günlük ortalama değeri ise 4.18 kWh/m² 'dir [16].


Bu çalışma Afyonkarahisar ve Elazığ illerinin güneş enerjisi potansiyelini değerlendirmek amacıyla, güneş ışıınımı ve ilgili iklimsel faktörlerin analizi üzerine yapılmıştır. Türkiye, özellikle güneş ışıınımı bakımından zengin bir ülke olup, bu çalışma iki farklı şehirde, Afyonkarahisar ve Elazığ şehirlerine ait verilerle yapılan analizleri içermektedir. Güneş ışıınımını etkileyen çeşitli çevresel faktörler, bu şehirlerin yerel iklim koşullarını yansıtacak şekilde değerlendirilmiştir. Afyonkarahisar ve Elazığ illeri, sahip oldukları farklı iklimsel özellikler göz önünde bulundurularak seçilmiştir. Afyonkarahisar, tipik karasal iklim koşullarına sahip olup kışları soğuk ve karlı, yazları ise sıcak ve kurak geçmektedir. Buna karşılık Elazığ, yarı kurak/karasal iklim özellikleri

göstermekte ve daha az yağışlı, sıcak ve kurak yazlara sahiptir. Bu iklimsel farklılıklar, makine öğrenmesi modellerinin performanslarının çeşitli coğrafi ve iklimsel koşullar altında karşılaştırmalı olarak değerlendirilmesine olanak tanımaktadır.

Veri seti, NASA tarafından sağlanan açık erişimli veriler kullanılarak oluşturulmuştur. Bu veriler, sıcaklık, rüzgar hızı, bağıl nem, basınç, gün, ay ve güneş ışıınımı verilerini içermektedir. Bu faktörler, güneş ışıınımı üzerindeki etkileri belirlemek için modelleme sürecinde önemli değişkenler olarak seçilmiştir. Veriler, Ocak 2000- Aralık 2024 tarihleri arasındaki dönemi kapsayan zaman diliminde, her iki şehir için toplanmış ve her bir şehir için 9 132 satırdan oluşan veri setleri oluşturulmuştur [17]. Veri setine deklinasyon açısı hesaplanarak eklenmiştir. Dünya'nın güneş

etrafındaki hareketi sırasında gezegenin eksenini yaklaşık 23.45 derece eğik bir pozisyonundadır. Uzaydan bakıldığında, Dünya'nın eksenini sabit kalır ve gezegen, güneş etrafında döner. Güneşin deklinasyonu, Dünya'nın ekseninin, güneş ile Dünya arasındaki çizgiye dik olan bir düzlemle yaptığı açı olarak tanımlanır [18]. Deklinasyon açısı, hesaplamaların yapıldığı ayı temsil eden günün yıl içindeki gün numarasına (n) bağlı olarak değişen bir parametre olup, Eşitlik 1 ile hesaplanır [19]. Şekil 2'de, Türkiye'nin şehir düzeyinde ayrıntılı bir güneş enerjisi potansiyeli verilmiştir [16].

$$\delta = 23.45 \sin \left(360 \cdot \frac{(284 + n)}{365} \right) \quad (1)$$



Şekil 2. Güneş Enerjisi Potansiyel Haritası Afyonkarahisar ve Elazığ (Solar Energy Potential Map Afyonkarahisar and Elazığ)

Modellemede kullanılan veri setindeki değişkenlerin betimsel istatistiksel özellikleri Tablo 1'de verilmiştir. Tabloda, her bir değişken için ortalama, medyan, minimum, maksimum ve standart sapma gibi temel istatistiksel ölçütler yer almaktadır. Bu bilgiler, veri setinin genel dağılımı hakkında fikir vermekte ve modelleme sürecinde kullanılacak verilerin analizine ışık tutmaktadır.

2.2.Makine Öğrenmesi Yöntemleri (Machine Learning Methods)


Çalışmada, güneş ışıınımı tahmini için farklı makine öğrenimi modelleri kullanılmıştır. Modellerin doğruluğunu artırmak ve sonuçların güvenilirliğini sağlamak amacıyla çeşitli yöntemler uygulanmıştır. Veri seti, eksik veriler ve aykırı değerler açısından kontrol edilmiş, ardından normalizasyon işlemleri yapılmıştır. Literatür taraması sonucunda belirlenen bağımsız değişkenler kullanılarak modelleme süreci gerçekleştirilmiştir.

Tablo 1. Veri setinin betimsel istatistikleri (Descriptive statistics of the dataset)

		Elazığ				Afyonkarahisar			
		min	ort	maks	Std sap	min	ort	maks	Std sap
Girdi değişkenleri	Sıcaklık	-18.34	13.16	33.87	10.67	-16.27	10.33	29.51	8.66
	Rüzgar hızı	0.42	1.90	9.03	0.84	0.54	2.56	11.31	1.20
	Bağıl nem	10.76	56.50	99.51	21.58	21.35	66.35	99.80	16.59
	Basınç	86.60	88.39	89.87	0.46	84.72	87.52	88.94	0.44

	Deklinasyon	-	23.45	0.00	23.45	16.59	-	23.45	0.00	23.45	16.59
Hedef değişken	Işınım		0.21	4.86	9.25	2.49	0.17	4.73	9.15	2.30	

Çalışmada, RF, XGB, SVR, MLR gibi farklı modeller kullanılmıştır. Bu yöntemlerin her biri, güneş ışınlamı tahmini yapmak için farklı özelliklere ve avantajlara sahiptir. Özellikle XGB gibi algoritmalar, güçlü öğrenme kapasitesine sahiptir. MLR gibi klasik regresyon modelleri ise daha basit ve hızlı çözümler sunmaktadır. Eğitim ve test veri setlerinin oranı sırasıyla %80 ve %20 olarak belirlenmiştir. Şekil 3'de çalışmada kullanılan makine öğrenimi sürecine ait genel yapı sunulmuştur. Bu yapıda; girdi olarak kullanılan veri özellikleri, uygulanan modelleme yöntemleri ve elde edilen çıktı değerleri arasındaki ilişki görsel olarak gösterilmektedir. Modelleme süreci Python programlama dili kullanılarak Jupyter Notebook ortamında gerçekleştirilmiştir.




Şekil 3. Girdi-Model-Çıktı Akış Diyagramı (Input-Model-Output Flow Diagram)

Çalışmada modellerin doğruluğunu artırmak ve aşırı uyum (overfitting) problemini önlemek amacıyla k-katlı çapraz doğrulama (k-Fold Cross Validation) yöntemi kullanılmıştır. Bu yöntem algoritmaların performansını değerlendirmek ve genelleme kabiliyetini objektif bir şekilde ölçmek amacıyla sıklıkla kullanılan yöntemlerden biridir. Bu yöntemde, veri kümesini k eşit parçaya böler; her bir iterasyonda bir fold test verisi olarak ayrılırken, kalan k-1 fold eğitim için kullanılır. Bu işlem k kez tekrarlanır ve her defasında model, farklı bir eğitim/test bölmesi üzerinde yeniden eğitilir. Şekil 4 'de k-katlı çapraz doğrulama şeması verilmiştir.

Bu çalışmada, k değeri 10 olarak seçilmiş ve eğitim veri seti 10 alt kümeye bölünerek her alt küme sırayla test seti olarak kullanılmıştır. Bu işlem, modelin genel performansını daha güvenilir bir şekilde ölçmek amacıyla tekrarlanmış ve sonuçların ortalaması alınmıştır. Sonuçlar, kullanılan farklı modellerin doğruluk oranları ve genel

performansları açısından karşılaştırılmıştır. Bu sayede, solar radyasyon tahmini için etkili olan model belirlenmiştir.



Şekil 4. k-katlı çapraz doğrulama (k-fold cross-validation)

2.2.1. Rastgele Orman (Random Forest)

RF, sınıflandırma ve tahminleme işlemlerinde kullanılan bir makine öğrenmesi modelidir. Makine öğrenmesi algoritmaları ve yapay zeka modellerinin eğitimi için yüksek kaliteli ve yeterli miktarda veriye ihtiyaç vardır. Sistem performans verileri, algoritmaların iyileştirilmesi, yazılım ve donanım verimliliğinin artırılması, kullanıcı davranışlarının analizi, desen tanıma, karar verme, tahmine dayalı modelleme ve problem çözme açısından büyük önem taşır. Çeşitli veri toplama ve işleme yöntemlerinin entegrasyonu, bu süreçlerde hassasiyet ve yenilik sağlar. Bu teknik, karar ağaçları konseptine dayanır. RF, birçok karar ağacı oluşturur ve bunların çıktılarının birleşimiyle nihai tahmini üretir. Her bir ağaç, verinin rastgele bir alt kümesi ile eğitilir. Bu yapı, modelin genelleme yeteneğini artırır ve aşırı öğrenme (overfitting) problemini azaltır. Ayrıca, eksik verilerle ve dengesiz veri kümeleriyle başa çıkma konusunda etkilidir. Rastgele değişken seçiminin yol açtığı sorunları da azaltır. Bu yönleriyle RF, makine öğrenmesi alanında en etkili ve güçlü yöntemlerden biri olarak kabul edilir ve otomatik sınıflandırma, veri tahmini ve denetimli öğrenme gibi birçok alanda yaygın olarak kullanılır[20].

2.2.3. XGBoost (Extreme Gradient Boosting)

XGB, makine öğrenmesinde yaygın olarak tercih edilen ve karar ağaçları temelli bir topluluk algoritmasıdır. Bu yöntem, gradyan artırma algoritmasının geliştirilmiş bir versiyonu olarak tasarlanmış olup, özellikle büyük ve karmaşık veri kümeleri üzerinde yüksek doğrulukla tahminler

yapabilme kabiliyetiyle öne çıkar[21]. Algoritma, ardışık olarak inşa edilen zayıf tahminleyicilerin (genellikle karar ağaçlarının) birleşiminden güçlü bir model oluşturarak öğrenme sürecini gerçekleştirir. Bu süreçte, her yeni model, bir önceki modellerin yaptığı hataları azaltmayı hedefler. XGB'un temel farkı, bu süreci daha verimli hâle getirmek için çeşitli mühendislik ve matematiksel optimizasyonlar kullanmasıdır. XGB'un klasik gradyan artırma algoritmalarına göre en büyük avantajları arasında paralel işlemeye uygunluğu, eksik verilerle başa çıkma yeteneği, overfitting'i azaltmak için düzenleme içermesi ve özel olarak geliştirilmiş optimizasyon teknikleri yer alır [22].

XGB algoritmasının matematiksel temeli, modelin tahminleme sürecini, optimizasyon yaklaşımını ve düzenleme mekanizmasını içeren belirli denklemlerle ifade edilmektedir. Bu kapsamda, XGB'un temel denklemleri eşitlik 2,3, ve 4'te verilmiştir [10].

$$obj(\theta) = L(\theta) + \Omega(\theta) \quad (1)$$

$$\Omega(f) = \gamma T + \left(\frac{1}{2}\right) \lambda \sum_{i=1}^T \omega_i^2 \quad (2)$$

$$obj = \sum_{i=1}^T \left[G_i \omega_i + \left(\frac{1}{2}\right) (H_i + \lambda) \omega_i^2 \right] + \gamma T \quad (3)$$

2.2.3. Çoklu Lineer Regresyon (Multiple Linear Regression)

MLR bir bağımlı değişkenin (hedef değişkenin) birden fazla bağımsız değişkene (girdi değişken) dayalı olarak tahmin edilmesini sağlayan istatistiksel bir modeldir. LR'nin bir uzantısıdır ve birden fazla girdi değişkeni kullanılmaktadır [23]. Eşitlik 5'te verilen MLR'nin temel formülünde; Y değeri bağımlı değişken, X değerleri bağımsız değişkenleri, β_0 değeri Y değerini kesen noktayı, $\beta_1, \beta_2, \beta_n$ değerleri bağımsız değişkenlerin katsayılarını ve ϵ değeri hata terimini temsil etmektedir.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon \quad (4)$$

2.2.4. Destek Vektör Regresyonu (Support Vector Regression)

SVR, destek vektör makineleri (Support Vector Machines-SVM) algoritmasının regresyon problemlerine uyarlanmış bir türevidir ve özellikle doğrusal olmayan ilişkilerin söz konusu olduğu karmaşık veri yapılarında etkili bir regresyon yöntemidir[24]. SVR'nin temel amacı, tahmin edilen değerler ile gerçek değerler arasındaki farkın belirli bir tolerans değeri (ϵ) içinde kalmasını sağlarken, aynı zamanda modelin genel karmaşıklığını kontrol altında tutmaktır. Bu

doğrultuda SVR, hata marjını aşan örnekler için ceza terimleri tanımlayarak hem esneklik hem de genelleme kapasitesi yüksek bir model elde etmeye çalışır. SVR, bu hedefe ulaşmak için aşağıdaki biçimde tanımlanan bir kuadratik optimizasyon problemi çözmektedir: SVR'nin temel optimizasyon fonksiyonu, ağırlık vektörünün normunun karesinin yarısı $\frac{1}{2} \|w\|^2$ ile hata terimlerinin mutlak değerlerinin ceza katsayısı C ile çarpımının toplamından oluşur. Bu ifade, hem modelin genel karmaşıklığını kontrol altında tutmayı hem de tolerans sınırını aşan örneklerin toplam hatasını minimize etmeyi hedefler. Modelin tahmin ettiği değer ile gerçek değer arasındaki fark, belirli bir tolerans değeri olan ϵ içinde kalmalı; ancak bu sınırı aşan sapmalar, $|\xi_i|$ hata terimleri ile telafi edilir. Her bir gözlem için $|y_i - w_i x_i| \leq \epsilon + |\xi_i|$ koşulu sağlanmalıdır. Böylece SVR, küçük hataları görmezden gelirken, tolerans sınırının ötesine geçen sapmaları denetleyerek esnek ancak genelleyici bir regresyon modeli oluşturur [25]. Eşitlik 6 ve 7'de SVR modeline ait denklem verilmiştir.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n |\xi_i| \quad (5)$$

$$|y_i - w_i x_i| \leq \epsilon + |\xi_i| \quad i = 1, 2, \dots, n \quad (6)$$

2.2.5. Modelleri Değerlendirme (Model Evaluation)

Bu çalışmada geliştirilen makine öğrenimi modellerinin performansını değerlendirmek amacıyla çeşitli istatistiksel performans metrikleri kullanılmıştır. Kullanılan değerlendirme kriterleri; belirleme katsayısı (R^2), Ortalama Mutlak Hata (MAE), Hata Kareleri Ortalaması (MSE), Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) şeklindedir. Bu kriterlere ait denklemler 8,9,10,11 ve 12'de verilmiştir.

R^2 modelin bağımlı değişkendeki toplam varyansın ne kadarını açıkladığını gösteren bir uygunluk ölçüsüdür. 1'e yakın R^2 değerleri, modelin tahmin gücünün yüksek olduğunu; 0'a yakın değerler ise açıklayıcılığının zayıf olduğunu ifade eder.

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - y_{ort})^2} \quad (7)$$

MSE hata değerlerinin karelerinin ortalaması alınarak hesaplanır ve büyük hatalara daha fazla ağırlık vererek modelin doğruluğunu değerlendirir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

RMSE ise MSE'nin karekökü alınarak elde edilir ve tahmin hatalarının standart sapmasını ifade eder. RMSE (Root Mean Square Error), tahmin edilen değerlerle gerçek değerler arasındaki farkları ölçen ve hata büyüklüğünü gösteren bir istatistiksel ölçüdür. Başka bir deyişle, RMSE tahmin hatalarının standart sapmasını temsil eder. Bu değer, regresyon modelinin veriye ne kadar yakın tahminlerde bulunduğunu gösterir; yani kalıntıların ne kadar yayıldığını ifade eder. RMSE, 0 ile sonsuz arasında bir değer alabilir. RMSE'nin sıfıra yakın olması, modelin tahminlerinde yüksek doğruluk sağladığını ve hata oranının düşük olduğunu gösterir. Bu nedenle ideal olan, RMSE değerinin mümkün olduğunca düşük olmasıdır. RMSE'nin düşük olması, modelin gerçek değerlere yakın tahminler yaptığını gösterir [26].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

MAE tahmin edilen ve gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını alarak modelin genel hata büyüklüğünü ifade eder. MAE'nin düşük olması, modelin genellikle doğru tahminlerde bulunduğunu gösterir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

MAPE tahmin hatalarının yüzdesel olarak ne kadar sapma gösterdiğini ölçen bir metriktir. Göreceli hata oranını verdiği için, özellikle farklı ölçeklerdeki verilerin karşılaştırılmasında sıkça tercih edilir. MAPE değeri %10'un altında olan modeller “çok

iyi”, %10 ile %20 arasında olanlar “iyi”, %20 ile %50 arasındakiler “kabul edilebilir” ve %50'nin üzerindeki ise “hatalı” olarak sınıflandırılır.

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \right) * 100 \quad (11)$$

3.BULGULAR VE TARTIŞMA (RESULTS AND DISCUSSION)

Bu çalışmada, Afyonkarahisar ve Elazığ illerine ait veri setleri kullanılarak MLR, SVR, XGB ve RF modelleri ile tahmin yapılmıştır. Veri seti analiz öncesinde betimleyici istatistikler aracılığıyla incelenmiş veri ön işleme adımları gerçekleştirilmiştir. Veri seti 10 katlı çapraz doğrulama yöntemiyle eğitilip test edilmiş ve model performansları çeşitli hata metrikleri üzerinden değerlendirilmiştir. Modellere ait R², RMSE, MSE, MAE ve MAPE performans metrikleri Tablo 2’de sunulmuştur. Afyonkarahisar ve Elazığ illerinde uygulanan MLR, SVR, XGB ve RF modelleri, genel olarak birbirine yakın doğruluk değerleri üretmiştir. RF modeli, her iki şehirde de yüksek R² ve düşük RMSE, MAE değerleriyle güçlü tahmin gücü sergilemiştir. XGB ve SVR modelleri de başarılı sonuçlar üretmiş olmakla birlikte, RF modelinin istikrarı ve genel hata metriklerinde başarılıdır.

Tablo 3’te Afyonkarahisar ve Elazığ illerine ait korelasyonlar MLR kullanarak geliştirilmiştir. Bu korelasyonlar, her iki şehirde güneş ısınımını etkileyen faktörler arasındaki ilişkilerin daha iyi anlaşılmasını sağlamaktadır. Elde edilen sonuçlar, güneş ısınımı ile zaman, hava sıcaklığı ve güneş açısı gibi bağımsız değişkenler arasında güçlü pozitif ilişkiler olduğunu göstermektedir. Bu bulgular, her iki şehirde de güneş ısınımını tahmin etmek için kullanılan MLR modelinin etkinliğini desteklemektedir.

Tablo 2. Elazığ ve Afyonkarahisar illeri için farklı modellerin belirleme katsayısı ve hata metrikleri



(Coefficient of determination and error metrics of different models for Elazığ and Afyonkarahisar provinces)

	Elazığ				Afyonkarahisar			
	MLR	SVR	XGB	RF	MLR	SVR	XGB	RF
R²	0.8961	0.9243	0.9740	0.9887	0.8645	0.9121	0.9702	0.9866
RMSE	0.80	0.69	0.40	0.26	0.85	0.68	0.40	0.27
MSE	0.65	0.47	0.16	0.07	0.72	0.47	0.16	0.07
MAE	0.61	0.46	0.29	0.19	0.65	0.48	0.29	0.19
MAPE	%20.8	%16.3	%9.85	%6.51	%19.91	%15.14	%8.97	%6.12

Tablo 1. MLR ile Geliştirilen Güneş Işınımı Korelasyonları (Solar Irradiance Correlations Improved with MLR)



	Korelasyon	R ²
Afyonkarahisar	4.7382-0.0417.T-0.0692.W-0.7731.R+0.3037.P+1.6964.D	0.8638
Elazığ	4.8705-0.5043.T+0.0004.W-1.2177.R+0.2414.P+2.1805.D	0.8955

Şekil 5 ve 6’te RF modelinin Afyonkarahisar ve Elazığ için tahmin performansı verilmiştir. Grafiklerde tahmin değerlerinin gerçek değerlere oldukça yakın olduğu görülmektedir. Noktaların referans çizgisine yakın konumlanması, RF modelinin güneş ışıınımı değerlerini doğru biçimde öngörebildiğini ve bölgesel değişkenliği başarıyla yakaladığını göstermektedir. RF algoritmasının hem Afyonkarahisar hem de Elazığ gibi farklı iklim koşullarına sahip bölgelerde tutarlı ve güçlü bir tahmin performansı sergilediğini ortaya koymaktadır.

**Şekil 5.** Afyonkarahisar-RF Modeli Tahmin Performansı (Afyonkarahisar-RF Model Prediction Performance)**Şekil 6.** Elazığ-RF Modeli Tahmin Performansı (Elazığ-RF Model Prediction Performance)


Şekil 7 ve 8’de XB modelinin Afyonkarahisar ve Elazığ için tahmin performansı verilmiştir. Her iki şehirde de tahmin edilen ve gözlemlenen değerler

arasında bir uyum gözlemlenmiş, veri noktalarının referans çizgisine yakınlığı modelin doğruluk düzeyini ortaya koymuştur. Bu bulgular, XGB modelinin farklı iklim koşullarına sahip bölgelerde dahi güçlü bir tahmin kabiliyeti sergilediğini ve güneş ışıınımı tahmini için etkili bir yöntem olduğunu göstermektedir.


**Şekil 7.** Afyonkarahisar-XGB Modeli Tahmin Performansı (Afyonkarahisar-XGB Model Prediction Performance)**Şekil 8.** Elazığ-XGB Modeli Tahmin Performansı (Elazığ-XGB Model Prediction Performance)

Şekil 9 ve 10’da, sırasıyla Afyonkarahisar ve Elazığ illeri için MLR modelinin tahmin performansı verilmiştir. Gerçek ve tahmin edilen değerlerin karşılaştırılması ve modelin performansını ortaya koymaktadır. Ancak grafikler incelendiğinde, MLR modelinin tahminlerinin referans çizgisinden belirgin sapmalar gösterdiği ve veri noktalarının

daha dağınık bir şekilde yer aldığı görülmektedir. RF ve XGB modellerine kıyasla daha düşük bir genel doğruluk ve sınırlı öngörü gücü sergilemiştir.




Şekil 9. Afyonkarahisar MLR Modeli Tahmin Performansı (Afyonkarahisar MLR Model Prediction Performance)




Şekil 10. Elazığ-MLR Modeli Tahmin Performansı (Elazığ-MLR Model Prediction Performance)

Şekil 11 ve 12’de sırasıyla Afyonkarahisar ve Elazığ illeri için SVR modelinin tahmin performansını göstermektedir. Her iki şekil de x ekseninde tahmin edilen değerler ve y ekseninde gerçek değerler yer almaktadır. Grafiklerdeki doğrusal uyum çizgisi ($y = x$), modelin tahminlerinin ne kadar doğru olduğunu gösteren bir referans çizgisidir. Gerçek değerler ile tahmin edilen değerler arasındaki yakınlık arttıkça, modelin başarısı da artmaktadır.




Şekil 1. Afyonkarahisar SVR Modeli Tahmin Performansı (Afyonkarahisar SVR Model Prediction Performance)



Şekil 2. Elazığ-SVR Modeli Tahmin Performansı (Elazığ-SVR Model Prediction Performance)

Modelleme sonuçlarına göre, en yüksek R^2 değerine ulaşan model RF olmuştur. Bu, modelin bağımlı değişkeni açıklama gücünün diğer modellere göre daha yüksek olduğunu göstermektedir. Özellikle RF ve XGB modelleri, doğrusal olmayan yapıları başarıyla modelleyebildikleri için doğrusal modeller olan MLR ve SVR'ye kıyasla daha başarılı sonuçlar vermiştir. RMSE ve MAPE değerlerinin düşük olması, modelin tahmin hatalarının nispeten düşük olduğunu ortaya koymuştur. Şekil 13’ de modellere göre R^2 değerleri verilmiştir. Sonuç olarak, kullanılan farklı modelleme tekniklerinin veri seti üzerindeki performansları değerlendirilmiş ve en uygun modelin seçimi objektif hata metriklerine dayandırılmıştır.



Şekil 13. R² Değerleri ile Model Performansının Karşılaştırılması- Elazığ ve Afyonkarahisar (Comparison of Model Performance with R² Values - Elazığ and Afyonkarahisar)

4.SONUÇLAR (CONCLUSIONS)

Bu çalışmada, Afyonkarahisar ve Elazığ illerine ait veri setleri kullanılarak dört farklı makine öğrenmesi modeli (MLR, SVR, XGBoost, RF) ile güneş ışıınımı tahmini gerçekleştirilmiştir. Modelleme süreci sonucunda, özellikle RF ve XGB algoritmalarının yüksek doğruluk oranları ve düşük hata metrikleri ile diğer modellere kıyasla daha başarılı performans sergilediği belirlenmiştir.

Model performanslarının karşılaştırılmasında kullanılan R², RMSE, MSE, MAE ve MAPE gibi metrikler, verinin doğrusal ve doğrusal olmayan yapılar barındırdığını, bu nedenle doğrusal modellere kıyasla ensemble yöntemlerinin daha etkili sonuçlar verdiğini göstermektedir. Elazığ ili için geliştirilen RF modeli en başarılı sonuçları üretmiş ve bu modelle elde edilen performans metrikleri sırasıyla; R²=0.9887, MAE=0.19, MAPE=%6.51, MSE=0.07 ve RMSE=0.26 olarak hesaplanmıştır. Benzer şekilde, Afyonkarahisar ili için de RF modeliyle oldukça yakın sonuçlar elde edilmiş olup, R²=0.9866, MAE=0.19, MAPE=%6.12, MSE=0.07 ve RMSE=0.27 olarak hesaplanmıştır. Bu durum modellerin farklı coğrafi bölgelerde tutarlı ve güvenilir tahminler yapabildiğini göstermektedir. Her iki ilde de R² değerinin 0.98'in üzerinde olması, kurulan modellerin veriyle yüksek düzeyde uyum sağladığını ortaya koymaktadır.10 katlı çapraz doğrulama uygulanması ise modellerin genellenebilirliğini artırmış ve elde edilen sonuçların güvenilirliğini sağlamıştır.

Çalışma, farklı coğrafi bölgelerden elde edilen verilerin makine öğrenmesi yöntemleriyle başarılı şekilde analiz edilebileceğini ortaya koymakta, aynı zamanda bu tür modellerin ileride farklı alanlarda (örneğin tarım, meteoroloji, ekonomi)

uygulanabilirliğine de ışık tutmaktadır. Gelecekte, daha büyük ve çeşitli veri setlerinin kullanılması, hiperparametre optimizasyonunun yapılması ve farklı algoritmaların denenmesi ile model başarıları daha da artırılabilir; böylece güneş ışıınımı tahmini alanındaki bilgi birikimine önemli katkılar sağlanacaktır. Ayrıca, mevcut bulguların enerji planlaması ve sürdürülebilir enerji politikalarının geliştirilmesinde yol gösterici olması beklenmektedir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

The author of this article declares that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Abdülkadir KOÇER: Veri analizi yapma, sonuçları değerlendirme, yorumlama, makale düzenleme.

Data analysis, evaluation, interpretation of results and manuscript editing.

İlayda PALA: Veri analizi yapma, sonuçları değerlendirme, yorumlama ve makalenin yazımı.

Data analysis, evaluation and interpretation of results, and manuscript writing.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] Global Energy Review 2025. [Online]. Available: www.iea.org
- [2] Bekçioğulları MF, et al. Güneş enerjisinin kısa-dönem tahmininde farklı makine öğrenme yöntemlerinin karşılaştırılması. *EMO Bilimsel Dergi*. 2021; 11(22): 37–45.
- [3] Demolli H, Dokuz A, Gokcek M, Ecemiş A. Makine öğrenmesi algoritmalarıyla güneş enerjisi tahmini: Niğde ili örneği. *International Turkic World Congress on Science and Engineering*. 2019; 783.
- [4] Demirgöl T, Demir V, Sevimli MF. Farklı makine öğrenmesi yaklaşımları ile Türkiye'nin solar radyasyon tahmini. *Geomatik*. doi:10.29128/geomatik.1374383.
- [5] Kanksha H, Singh H, Laxmi V. Supervised learning algorithm: A survey. *Communications in Computer and Information Science*. 2021; 1393: 71–78. doi:10.1007/978-981-16-3660-8_7.
- [6] Mienye ID, Sun Y. A survey of ensemble learning: Concepts, algorithms, applications, and prospects. *Institute of Electrical and Electronics Engineers Inc*. 2022. doi:10.1109/ACCESS.2022.3207287.
- [7] Villegas-Mier CG, Rodriguez-Resendiz J, Álvarez-Alvarado JM, Jiménez-Hernández H, Odry Á. Optimized random forest for solar radiation prediction using sunshine hours. *Micromachines (Basel)*. 2022; 13(9). doi:10.3390/mi13091406.
- [8] Ercan U, Kocer A. Prediction of solar irradiance with machine learning methods using satellite data. *Int J Green Energy*. 2024; 21(5): 1174–1183. doi:10.1080/15435075.2024.2305857.
- [9] Sezikli NM, Alkan Ü, Zontul M, Elabiad Z. Forecast analysis of renewable solar energy production using meteorological data with machine learning methods. *JAST*. 2024; 17(2): 180–202.
- [10] Bamisile O, Ejayi CJ, Osei-Mensah E, Chikwendu IA, Li J, Huang Q. Long-term prediction of solar radiation using XGBoost, LSTM, and machine learning algorithms. 2022 4th Asia Energy and Electrical Engineering Symposium (AEEES). *Institute of Electrical and Electronics Engineers Inc.*; 2022. p. 214–218. doi:10.1109/AEEES54426.2022.9759719.
- [11] Sagar A, Hole S, Kolluru V. Optimizing solar radiation forecasting for renewable energy systems. *Solar Energy and Sustainable Development Journal*. 2025; 14(1): 395–315. doi:10.51646/jsesd.v14i1.386.
- [12] Azam F, Akhtar N, Husain S. Development of machine learning models for the estimation of diffuse solar radiation in the humid-subtropical climatic region of India. *Discover Atmosphere*. 2025; 3(1): 7. doi:10.1007/s44292-025-00030-0.
- [13] Wan P, He Y, Zheng C, Wen J, Gu Z. Estimation of solar diffuse radiation in Chongqing based on random forest. *Energies (Basel)*. 2025; 18(4). doi:10.3390/en18040836.
- [14] Küçüktopçu E, Cemek B, Simsek H. Comparative analysis of single and hybrid machine learning models for daily solar radiation. *Energy Reports*. 2024; 11: 3256–3266. doi:10.1016/j.egyr.2024.03.012.
- [15] Yuzer EO, Bozkurt A. Instant solar irradiation forecasting for solar power plants using different ANN algorithms and network models. *Electrical Engineering*. 2024; 106(4): 3671–3689. doi:10.1007/s00202-023-02067-z.
- [16] GEPA.[Online].Available:<https://gepa.enerji.gov.tr/MyCalculator/>.Accessed:Apr.28,2025.
- [17] POWER | DAV. [Online]. Available: <https://power.larc.nasa.gov/data-access-viewer/>. Accessed: Apr. 28, 2025.
- [18] Şenpınar A. Güneş açılarına bağlı olarak optimum sabit güneş paneli açısının hesaplanması. *Fırat Üniversitesi Doğu Araştırmaları Dergisi*. 2006; 4(2): 36–41.
- [19] Çağlar A. Farklı derece-gün bölgelerindeki şehirler için optimum eğim açısının belirlenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 2017; 22(2): 849. doi:10.19113/sdufbed.94899.
- [20] Salman HA, Kalakech A, Steiti A. Random forest algorithm overview. *Babylonian Journal of Machine Learning*. 2024; 2024: 69–79. doi:10.58496/bjml/2024/007.
- [21] Zhang W, Wu C, Zhong H, Li Y, Wang L. Prediction of undrained shear strength using extreme gradient boosting and random forest based on Bayesian optimization. *Geoscience Frontiers*. 2021; 12(1): 469–477. doi:10.1016/j.gsf.2020.03.007.
- [22] Chen T, Guestrin C. XGBoost: A scalable tree boosting system. In: *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Association for Computing Machinery; 2016.p.785-794. doi:10.1145/2939672.2939785.
- [23] Yousuf MU, Ali A, Umair M. Assessing the impact of air pollution on global and diffuse solar radiation in Karachi, Pakistan: A comparative analysis of multiple linear regression and artificial neural network models.

- Theor Appl Climatol. 2025; 156(5): 261.
doi:10.1007/s00704-025-05499-8.
- [24] Alkesaiberi A, Harrou F, Sun Y. Efficient wind power prediction using machine learning methods: A comparative study. *Energies* (Basel). 2022; 15(7). doi:10.3390/en15072327.
- [25] Yu PS, Chen ST, Chang IF. Support vector regression for real-time flood stage forecasting. *J Hydrol (Amst)*. 2006; 328(3–4):704–716. doi:10.1016/j.jhydrol.2006.01.021.
- [26] Yetiz F, Terzioğlu M, Kayakuş M. An analysis of Turkish deposit banks' customer forecasting with machine learning methods. *Sosyoekonomi*. 2021; 29(50): 413–432. doi:10.17233/sosyoekonomi.2021.04.19.