

Makine Öğrenmesi Yöntemleriyle Güneş Radyasyon Tahmini (Solar Radiation Forecasting Using Machine Learning Methods)

¹Bayram KÖSE, ^{*1}Muhammed Şamil ÇİMEN ve ²Şakir KUZHEY

^{*1}İzmir Bakırçay Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, İzmir, Türkiye
bayram.kose@bakircay.edu.tr, 6017008@bakircay.edu.tr

²Kocaeli Üniversitesi, Karamürsel Denizcilik Meslek Yüksekokulu, Kocaeli, Türkiye
sakir.kuzey@kocaeli.edu.tr

Abstract

This study aims to predict solar radiation using meteorological data collected between 2020 and 2024 in the Menemen region of İzmir, Türkiye. Input features include temperature, pressure, humidity, wind direction, wind speed, and sunrise and sunset times. Two machine learning (ML) approaches—Multivariate Linear Regression (MLR) and Recurrent Neural Networks (RNN)—were applied. The performance of each model was evaluated using Mean Squared Error (MSE), Mean Absolute Error (MAE), and Coefficient of Determination (R^2). While MLR models achieved reasonable accuracy, RNN provided superior results by better capturing time-based patterns, making it more effective for Time Series Forecasting (TSF). The analysis was based on Meteorological Data (MD), and results support the potential of ML techniques in Sustainable Energy Management (SEM). This study demonstrates the applicability of data-driven modeling in solar radiation forecasting and provides a solid foundation for future research in sustainable energy planning.

Key words: Solar Radiation, Machine Learning (ML), Multivariate Linear Regression (MLR), Recurrent Neural Networks (RNN), Time Series Forecasting (TSF), Meteorological Data (MD), Sustainable Energy Management (SEM).

Özet

Bu çalışma, 2020–2024 yılları arasında İzmir’in Menemen bölgesinde toplanan meteorolojik veriler kullanılarak güneş radyasyonunun tahmin edilmesini amaçlamaktadır. Girdi değişkenleri arasında sıcaklık, basınç, nem, rüzgâr yönü ve hızı ile güneşin doğuş ve batış saatleri yer almaktadır. Makine öğrenmesi (ML) tabanlı iki yaklaşım olan Çok Değişkenli Doğrusal Regresyon (MLR) ve Yinelemeli Sinir Ağları (RNN) kullanılmıştır. Modellerin başarımı, Ortalama Kare Hata (MSE), Ortalama Mutlak Hata (MAE) ve Belirleme Katsayısı (R^2) gibi ölçütlerle değerlendirilmiştir. MLR modelleri makul doğruluk sağlasa da Zaman Serisi Tahmini (TSF) açısından RNN daha düşük hata oranları ve daha yüksek R^2 değerleriyle üstün performans göstermiştir. Meteorolojik Veriler (MD) üzerinden yapılan bu analiz, Sürdürülebilir Enerji Yönetimi (SEM) kapsamında makine öğrenmesi tekniklerinin potansiyelini ortaya koymakta ve güneş radyasyonu tahmininde gelecekteki çalışmalara sağlam bir temel sunmaktadır.

Anahtar Kelimeler: Güneş Radyasyonu, Makine Öğrenmesi (ML), Çok Değişkenli Doğrusal Regresyon (MLR), Yinelemeli Sinir Ağları (RNN), Zaman Serisi Tahmini (TSF), Meteorolojik Veriler (MD), Sürdürülebilir Enerji Yönetimi (SEM).

1. Giriş

Güneş radyasyonu, yalnızca yenilenebilir enerji üretiminin temel bileşeni olmakla kalmayıp aynı zamanda tarımsal faaliyetlerden iklim modellemelerine, kent planlamasından enerji arz-talep dengesine kadar çok geniş bir uygulama alanında kritik rol oynamaktadır. Güneşten gelen enerji akışı, yer yüzeyine ulaşmadan önce atmosferdeki birçok faktörden etkilenmekte, bu da tahmin sürecini hem önemli hem de karmaşık bir hale getirmektedir. Özellikle sürdürülebilir enerji politikalarının ve iklim değişikliği ile mücadele stratejilerinin merkezinde yer alan güneş enerjisinin etkin biçimde kullanılabilmesi için radyasyonun zamansal ve mekânsal dağılımının doğru tahmin edilmesi büyük önem taşımaktadır [1].

Son yıllarda artan enerji ihtiyacı ve fosil yakıt kaynaklarının çevresel etkileri, güneş enerjisi gibi temiz enerji kaynaklarına olan ilgiyi artırmıştır. Bu bağlamda, fotovoltaiik (PV) sistemlerin verimli işletilmesi ve enerji arzı planlaması gibi uygulamalarda, güneş radyasyonunun doğru şekilde tahmin edilmesi bir ön koşul haline gelmiştir [2].

Güneş enerjisi üretiminin doğasında var olan kesintili ve kontrol edilemez karakteristikler, elektrik şebekelerinde voltaj dalgalanmaları, yerel güç kalitesi bozulmaları ve stabilite sorunları gibi bir dizi operasyonel güçlük yaratmaktadır. Bu bağlamda, elektrik şebekesinin etkin işleyişi ve güneş enerjisi sistemlerindeki enerji akışlarının optimum yönetimi için güneş enerjisi çıkış gücünün hassas bir şekilde tahmin edilmesi zorunlu hale gelmektedir. Tahmin yeteneği, aynı zamanda rezerv kapasitelerinin belirlenmesi, güç sistemi planlaması, şebeke tıkanıklık yönetimi, stokastik üretim koşulları altında depolama sistemlerinin optimal işletimi ve elektrik piyasasında üretilen enerjinin ticarileştirilmesi açısından kritik öneme sahiptir. Tüm bu unsurlar, nihayetinde elektrik üretim maliyetlerinin düşürülmesine katkı sağlamaktadır. Yenilenebilir elektrik üretimindeki büyük varyasyonları minimize etmek amacıyla, depolama çözümlerini içeren sistem işletiminin kapsamlı bir şekilde tahmin edilmesi gerekliliği ortaya çıkmaktadır [3].

Geleneksel tahmin yöntemleri uzun yıllar boyunca istatistiksel regresyon tekniklerine dayalı olarak geliştirilmiştir. Özellikle Çok Değişkenli Doğrusal Regresyon (Multivariate Linear Regression - MLR) yöntemi, farklı meteorolojik değişkenler (sıcaklık, nem, rüzgar hızı, basınç vb.) ile güneş radyasyonu arasındaki doğrusal ilişkileri ortaya koymada yaygın biçimde kullanılmaktadır. MLR, modelin anlaşılabilirliğini ve yorumlanabilirliğini korurken, hesaplama açısından da oldukça pratiktir [4].

Güneş radyasyonu ile çevresel veriler çoğu zaman doğrusal olmayan kalıplar içerdiğinden, daha sofistike modellerin kullanılması gerekliliği ortaya çıkmıştır. Bu noktada, zaman serisi verileriyle çalışmak üzere geliştirilen Yinelemeli Sinir Ağları (Recurrent Neural Networks - RNN) öne çıkmaktadır. RNN modelleri, geçmiş veri noktalarını hafızasında tutarak bir sonraki adımı tahmin etme yeteneğine sahiptir. Bu özellik, güneş radyasyonunun zamana bağlı dinamik yapısını öğrenmek için önemli bir avantaj sağlamaktadır [5].

Güneş radyasyonu tahmini için derin öğrenme algoritmalarının performanslarını incelemek amacıyla bir YSA modeli ve bir RNN modeli geliştiren Pang ve arkadaşları, Eğitim süreci için Alabama'daki yerel bir hava istasyonundan elde edilen gerçek meteorolojik veriler kullanmışlardır.

Farklı örnekleme frekansları ve hareketli pencere algoritmalarını içeren çeşitli senaryolar kullanan RNN modeli için, hareketli pencere algoritmasının uygulanmasından sonra sonuçlarda iyileşme elde etmişlerdir. Ayrıca, bulutluluğun tahmin doğruluğu üzerinde önemli bir etkisi olabileceği de bulmuşlardır [6].

Güneş radyasyonunun doğru tahmini için bu tür saatlik ölçümlere dayalı yüksek çözünürlüklü veri setleri oldukça kritik öneme sahiptir. Nitekim Demirgöl ve arkadaşları, benzer bir çalışmada Türkiye geneli için farklı makine öğrenmesi algoritmalarını karşılaştırarak, meteorolojik verilerle desteklenen modellerin doğruluğunu vurgulamıştır [1]. Özellikle zaman bağımlı değişimlerin anlaşılması açısından, geçmiş verilere dayalı öğrenme kabiliyeti sunan yöntemlerin tercih edilmesi gerektiği ifade edilmektedir.

Uğuz ve arkadaşları güneş enerjisi üretim tahmini için yapılan çalışmasında, çeşitli makine öğrenmesi algoritmalarını karşılaştırmış ve RNN gibi yapay sinir ağı tabanlı modellerin, geleneksel yöntemlere kıyasla daha başarılı tahmin sonuçları verdiğini göstermiştir [2]. ML yöntemlerinin güneş radyasyonu tahminindeki başarımını karşılaştırmak ve güneş enerjisi gibi sürdürülebilir enerji alanlarında veri destekli karar mekanizmaları için katkı sağlamak önemlidir.

2. Veriler ve Yöntemler

Bu çalışmada, İzmir'in Menemen bölgesine ait 2020–2024 yılları arasındaki saatlik meteorolojik veriler kullanılarak güneş radyasyonu tahmini gerçekleştirilmiştir. Girdi parametreleri olarak sıcaklık, bağıl nem, basınç, rüzgar hızı ve yönü, güneşin doğuş-batış saatleri gibi değişkenler kullanılmış hem MLR hem de RNN modelleri oluşturulmuştur. Modeller, RMSE, MAE ve R^2 gibi standart performans ölçütleri üzerinden değerlendirilmiştir.

2.1. Değişkenler ve veriler

Bu çalışmada, makine öğrenmesi (ML) teknikleri kullanılarak atmosferik koşullara bağlı olarak yüksek değişkenlik gösteren güneş radyasyonu tahminlemede, modeli etkileyen değişkenlerin doğru seçimi büyük önem arz etmektedir. Çalışmada kullanılan temel giriş değişkenleri arasında zaman, sıcaklık, bağıl nem, atmosfer basıncı, rüzgar yönü ve hızı ile birlikte güneşin doğuş ve batış saatleri yer almaktadır. Bu veriler, 2020–2024 yılları arasında saatlik periyotlarla Menemen (İzmir) bölgesinde ölçülmüş ve modelleme sürecine dahil edilmiştir.

Verilerin tanımlayıcı istatistiksel bilgilerin yer aldığı Tablo 1'e göre; sıcaklık verileri ortalama 18,4 °C civarındadır ve düşük çarpıklık (0,020) değeriyle yaklaşık simetrik bir dağılım göstermektedir. Basınç değişkeni ise ortalama 966,68 hPa olmasına rağmen çok yüksek negatif çarpıklık (-4,312) ve yüksek basınlık (16,62) ile olağandışı düşük değerlerin veride etkili olduğunu işaret etmektedir. Nem için dağılım simetriye yakındır (çarpıklık: -0,391) ve değişkenlik sınırlıdır. Rüzgar hızı ve yağış değişkenleri pozitif çarpıklığa sahiptir (sırasıyla 1,133 ve 16,54). Güneşlenme süresi ve küresel güneş radyasyonu ise orta düzey varyans ve pozitif çarpıklıkla güneşli günlerin yoğun olduğu bir veri kümesini yansıtmaktadır.

Tablo 1 Saatlik Verilerin Tanımlayıcı İstatistiksel Verileri

İstatistiksel Ölçütler	Sıcaklık (°C)	Basınç (hPa)	Nem (%)	Rüzgar Hızı (m/s)	Yağış (mm)	Güneşlenme Süresi (saat)	Küresel Güneş Radyasyonu (W/m ²)
Ortalama (Mean)	18,40	966,68	57,96	2,18	0,0605	0,269	195,97
Ortanca (Median)	18,10	1012,9	59	1,90	0,0000	0,000	5,20
Standart Sapma (Std Dev)	8,87	213,10	23,38	1,55	0,5687	0,416	279,76
Varyans (Variance)	78,61	45412,33	546,54	2,41	0,3234	0,1732	78266,81
Standart Hata (Std Error)	0,043	1,04	0,115	0,0076	0,0028	0,0020	1,37
En Büyük (Max)	41,90	1037,1	100	13,8	20,6	1,00	1023,1
En Küçük (Min)	-2,20	0	0	0,00	0,00	0,00	0
Arahık (Range)	44,10	1037,1	100	13,8	20,6	1,00	1023,1
Basıklık (Kurtosis)	-0,690	16,62	0,115	2,12	360,48	-0,811	0,120
Çarpıklık (Skewness)	0,020	-4,312	-0,391	1,133	16,54	1,033	1,221
En Çok Tekrarlanan (Mod)	0	0	0	0	0	0	0
Toplam (Sum)	766049,1	40243672,3	2412814	90885,6	2518	11179,3	8158596,2
Gözlem Sayısı (N)	41631	41631	41631	41631	41631	41631	41631

Makine öğrenmesi ile model oluşturulurken veri kalitesi, model seçimi, artıklık ve veri dağılımı gibi faktörlerle modelin doğruluğu arttırılmaya çalışılır. Bir model oluşturulurken test sınıfına ait azınlık veri seti eğitim veri setine nadiren dahil edilir veya hiçbir zaman dahil edilmez. Bu genellikle model performansını ölçerken hatalara yol açar [7]. Bu nedenle, veri setlerinin işlenmesi ve analiz öncesi uygun şekilde hazırlanması kritik öneme sahiptir.

Bu hazırlık sürecinde, ham verilerden kaynaklı gürültü (parazit) içeren ya da aşırı uç değerler (outlier) barındıran gözlemler tespit edilip filtrelenmeli; veri ön işleme işlemleri yapılmalıdır. Ayrıca, zaman serisi verilerinde sıklıkla karşılaşılan eksik veriler, doğrusal interpolasyon, spline interpolasyonu, ileri-doldurma (forward fill) ya da zaman-ağırlıklı ortalama gibi tekniklerle tamamlanmalıdır. Bu sürece veri temizleme (data cleaning) ve ön işleme (preprocessing) adı verilir ve modelin doğruluğunu artırmada belirleyici rol oynar. Ayrıca, verilerin normalize edilmesi veya ölçeklendirilmesi (standardizasyon) gibi işlemler, öğrenme algoritmalarının daha etkili çalışmasını sağlar. Tüm bu aşamalar, makine öğrenmesi modellerinin dengeli, güvenilir ve genellenebilir sonuçlar üretmesi açısından zorunludur [7].

2.2.Makine Öğrenme Yöntemleri

ML modelleri, temsil imkansız olsa bile girdiler ve çıktılar arasındaki ilişkileri bulur; bu özellik, birçok durumda, örneğin desen tanıma, sınıflandırma sorunları, spam filtreleme ve ayrıca veri madenciliği ve tahmin sorunlarında makine öğrenimi modellerinin kullanılmasına olanak tanır. Küresel yatay ısıtım tahmininde, meteorolojik ve coğrafi parametrelere dayalı yapısal modeller, yalnızca tarihsel güneş ısıtım verilerini girdi olarak kullanan zaman serisi modelleri ve hem güneş ısıtımını hem de diğer değişkenleri dışsal parametreler olarak ele alan hibrit modeller kullanılabilmektedir [3]. Bu çalışmada MLR ve RNN modelleri kullanılarak dört farklı tahmin modeli geliştirilmiştir. MLR, giriş değişkenleri ile hedef değişken arasında doğrudan doğrusal ilişkiler kurarak tahmin yaparken; RNN, zaman serisi doğasını dikkate alarak geçmiş bilgileri modelde tutma ve kullanma yeteneğine sahiptir. Özellikle güneş radyasyonu gibi tahminleme çalışmalarında, RNN gibi hafızalı modelleri çalışmalarda kullanılmaktadır [8].

2.2.1. Çok Değişkenli Doğrusal Regresyon

MLR modeli, iki veya daha fazla bağımsız değişkenle bir bağımlı değişkenin tahminlem izin verir. Her bağımsız değişken giriş verisi, bağımlı değişken de çıkış verisi olarak bilinir. Regresyon, bağımlı bir değişkenin bağımsız bir değişken veya çok değişkene bağımlılığını değerlendirmek için kullanılan bir analiz şeklidir. Bu analizde bağımlı değişken y , bağımsız değişken veya değişkenler olduğunda $x_i(x_1, x_2, \dots, x_k)$ ile gösterilir. Bir bağımsız değişken varsa buna basit doğrusal regresyon, birden fazla varsa çoklu doğrusal regresyon denir [9]. MLR yönteminin denklemi aşağıda denklem (1)'de verilmiştir. Denklemden: y bağımlı değişkeni, $x_1, x_2, \dots, x_p$ bağımsız değişkenleri, β_0 sabit terimi, $\beta_1, \beta_2, \dots, \beta_p$ regresyon katsayılarını ve ϵ hata terimini ifade etmektedir **Error! Reference source not found..**

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon \quad (1)$$

Bu model matris formunda denklem (2) gibi yazılabilir.

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon} \quad (2)$$


$$\mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1p} \\ 1 & x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{np} \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{pmatrix}, \quad \boldsymbol{\epsilon} = \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{pmatrix}$$

Regresyon katsayıları genellikle en küçük kareler yöntemi kullanılarak tahmin edilmektedir **Error! Reference source not found..** Bu yöntem, hata terimlerinin karelerinin toplamını minimize ederek en uygun regresyon katsayılarını belirler [10],[11],[12].

2.2.2. Yinelemeli sinir ağları (RNN)

Yinelemeli sinir ağları (RNN), sıralı verileri işleyebilme yeteneği sayesinde zaman serisi tahminlerinde sıkça tercih edilen bir yapay sinir ağı modelidir. İlk kez 1980'li yıllarda geliştirilen RNN'ler, doğal dil işleme, konuşma tanıma, finansal zaman serileri analizi ve hava durumu tahmini gibi birçok alanda etkileyici sonuçlar elde etmişlerdir. RNN'lerin en önemli özelliklerinden biri, geri besleme mekanizması ile önceki zaman adımlarından gelen bilgiyi hafızasında tutabilmesi ve bunu mevcut çıktıları hesaplamada kullanabilmesidir. Aynı zamanda RNN, birimler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu bir YSA sınıfıdır. Bu kıyaslama Şekil 1'de incelenebilir. Bu özellik, geleneksel ileri beslemeli yapay sinir ağlarına (ANN) kıyasla zaman içindeki bağımlılıkları modellemeyi mümkün kılmaktadır [13].

Yapay Sinir Ağları (YSA) ve Yinelemeli Sinir Ağları (RNN)



Şekil 1 (a) İleri Beslemeli Yapay Sinir Ağı (FFNN) modeli, (b) Yinelemeli Yapay Sinir Ağı (RNN)[6]

RNN yapıları, standart çok katmanlı sinir ağlarına benzeyen bir giriş- gizli katman - çıkış katmanı düzenine sahiptir. Ancak burada, gizli katmanlar arasındaki bağlantılar zaman gecikmesi ile geri besleme yapmakta ve bu sayede geçmiş giriş bilgileri belirli bir süre boyunca ağ içinde saklanabilmektedir. Bu durum, uzun vadeli bağımlılıkların öğrenilmesine olanak tanır. Bununla birlikte klasik RNN modelleri, uzun zaman aralıkları boyunca bilgiyi taşıma konusunda zorluklar yaşayabilir ve "gradyan kaybolması" problemi nedeniyle uzun vadeli bağımlılıkları öğrenmede yetersiz kalabilir. Bu sorunu aşmak adına Uzun Kısa Süreli Bellek (LSTM) ve Kapılı Tekrarlayan Birim (GRU) gibi geliştirilmiş RNN varyantları önerilmiştir **Error! Reference source not found..** RNN de, Sistemin durum uzayı veya hafızası, gizli katman ile aşağıdaki denklem (3) ile tanımlanmaktadır

$$h_t = f_h(o_t) \quad (3)$$


Burada; $f_h(.)$ gizli katmanda bulunan aktivasyon fonksiyonudur. Eşik vektörü (bias) b_h şeklinde gösterilir ve W_{OH} gizli katman ağırlık katsayılarıdır ve gizli katmanda denklem (4) şekilde hesaplanır:

$$o_t = W_{IH}x_t + W_{HH}x_{t-1} + b_h \quad (4)$$

$$y_t = f_o(W_{HO}h_t + b_o) \quad (5)$$

Burada ; $f_o(.)$ aktivasyon fonksiyonu olarak ifade edilmektedir. Çıktı ardışık olarak değerlendirildiğinden, yukarıda gösterilen adımlar $t = (1, \dots, T)$ süresi boyunca tekrarlanmaktadır. Denklem (3) ve Denklem (5) bir RNN'nin zaman içinde yinelenebilen ve doğrusal olmayan durum denklemlerinden oluştuğunu gösterir. Her zaman adımında, gizli durumlar, giriş vektörüne dayalı olarak çıkış katmanında bir tahmin sağlar [6],[14].

Bu çalışmada, güneş radyasyonu tahmini için Yinelemeli Sinir Ağı (RNN) mimarisi kullanılmış ve bu yapının tahmin performansı değerlendirilmiştir. RNN modeli güneş radyasyonunun zamansal değişkenliğini analiz etmede önemli avantajlar sağlamaktadır.



Şekil 2 Yinelemeli Sinir Ağları (RNN) **Error! Bookmark not defined.** **Error! Reference source not found.**

3. Performans Ölçütleri ve Bulgular

Verilerin korelasyon analizi ile elde edilen doğrusallık etki dereceleri analizi **Tablo 2**. Korelasyon Analizi’de görüldüğü gibidir. Verilen korelasyon tablosuna göre, Bir saat sonraki radyasyon ölçüm değeri olan $s(t+1)$ değişkeni ile en güçlü ilişkiyi bir saat önceki küresel güneş radyasyonu ($r = 0.94$) göstermektedir. Bunu, yüksek düzeyde pozitif ilişkiyle güneşlenme süresi ($r = 0.76$) takip etmektedir. Sıcaklık, $s(t+1)$ ile orta düzeyde pozitif korelasyon göstermekte ($r = 0.41$) ve güneşlenme ile radyasyon değişkenleriyle de ilişkili görünmektedir. Buna karşılık, nispi nem, hem küresel güneş radyasyonu ($r = -0.39$) hem de $s(t+1)$ ($r = -0.31$) ile anlamlı ve ters yönlü ilişkidir. Aktüel basınç, rüzgar hızı ve toplam yağış değişkenlerinin $s(t+1)$ ile olan ilişkileri oldukça zayıftır ve etkileri sınırlıdır. Özellikle rüzgar hızı ve yağışın, diğer tüm değişkenlerle korelasyon katsayılarının düşük olması bu durumu desteklemektedir. Genel olarak, güneşe bağlı değişkenler (güneşlenme süresi ve radyasyon) $s(t+1)$ için en açıklayıcı faktörlerdir. Nem ve sıcaklık ikincil etkiler gösterirken, diğer meteorolojik faktörlerin etkisi düşüktür.

Tablo 2. Korelasyon Analizi

	Sıcaklık (°C)-k	Aktüel Basınç (hPa)	Nispi Nem (%)	Rüzgar Hızı (m÷sn)	Toplam Yağış (mm=kg÷m ²)	Güneşlenme Süresi (saat)-k	Küresel Güneş Radyasyonu	$s(t+1)$
Sıcaklık (°C)-k	1,00							
Aktüel Basınç (hPa)	0,21	1,00						
Nispi Nem (%)	-0,36	0,24	1,00					
Rüzgar Hızı (m÷sn)	0,09	0,09	-0,14	1,00				
Toplam Yağış (mm=kg÷m ²)	-0,06	0,01	0,12	0,06	1,00			
Güneşlenme Süresi (saat)-k	0,38	0,05	-0,33	0,19	-0,06	1,00		
Küresel Güneş Radyasyonu	0,49	0,03	-0,39	0,26	-0,06	0,78	1,00	
$s(t+1)$	0,41	0,03	-0,31	0,18	-0,05	0,76	0,94	1,00

3.1.Hata kareleri ortalamasının karekökü (RMSE)

RMSE, ölçülen değerler ile model tahminleri arasındaki hata oranını belirlemek için kullanılır. RMSE değeri sıfıra yaklaştıkça modelin tahmin yeteneğinin arttığı anlamına gelir. RMSE aşağıdaki şekilde hesaplanır. Gerçek ölçülen değer ile model kullanılarak hesaplanan değer arasındaki kare farkların toplamının ortalamasının kareköküdür. Bu istatistik, kısa vadeli ölçülen ve tahmin edilen model performansını karşılaştırmak için önemlidir [8]. Her zaman pozitif değer almasına rağmen ideal değeri sıfıra yakın olarak çıkması beklenmektedir ve hesaplama bağıntısı Denklem (6) de verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

3.2.Determinasyon Katsayısı

Regresyon analizi kullanılan çalışmalarda, tahmin edilen modelin kalitesinin değerlendirilmesi gerekmektedir. En yaygın yöntem R^2 determinasyon katsayısına bakmaktır. Determinasyon katsayısı bir denklemin kalitesinin bir ölçüsüdür, y 'deki değişimin ne kadarının R^2 ile gösterilen $\hat{y}$ modeli ile açıklanabileceğini gösterir ve 0 ile 1 arasında bir değer alır. $R^2=0$ ise y ile $\hat{y}$ arasında sıfır bağlantı olduğunu söyleyebiliriz. $R^2=1$ ise bu noktalar tam olarak regresyon doğrusu üzerindedir [15]. Yapılan çalışmalarda R^2 değerinin 1' yakın çıkması beklenmektedir ve denklem (7) veya denklem (8) ile hesaplanmaktadır.

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

veya

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

3.3.MLR model sonuçları

Bu çalışmada kullanılan meteorolojik veriler ışığında güneş radyasyonu tahmini gerçekleştirilmiştir. Modelleme sürecinde MLR yöntemi kullanılarak dört farklı model geliştirilmiş ve her modelde çeşitlilik göstermek üzere farklı bağımsız değişken kombinasyonları uygulanmıştır. Bağımsız değişkenler şu şekilde simgelenmiştir:

T : Saatlik Sıcaklık (°C)

P : Aktüel Basınç (hPa)

H : Nispi Nem (%)

W : Rüzgar Hızı (m/s)

R : Toplam Yağış (mm)

S : Güneşlenme Süresi (saat)

G : Küresel Güneş Radyasyonu (W/m²)

Y : Tahmin edilen bağımlı değişken (Güneş Radyasyonu - Wh/m²)

Her modelin doğrusal denklem formu aşağıda verilmiştir:

- M1 Modeli (Tüm meteorolojik değişkenler giriş olarak kullanılmıştır.):

$$Y = \beta_0 + \beta_1 T + \beta_2 P + \beta_3 H + \beta_4 W + \beta_5 R + \beta_6 S + \beta_7 G + \varepsilon$$

- M2 Modeli (Nem, rüzgar hızı, yağış ve güneş radyasyonu ile giriş yapılmıştır.):

$$Y = \beta_0 + \beta_1 H + \beta_2 W + \beta_3 R + \beta_4 S + \beta_5 G + \varepsilon$$


- M3 Modeli: (Sıcaklık, nem, güneşlenme süresi ve güneş radyasyonu kullanılmıştır.)

$$Y = \beta_0 + \beta_1 T + \beta_2 H + \beta_3 S + \beta_4 G + \varepsilon$$

- M4 Modeli: (Güneşlenme süresi ve küresel güneş radyasyonu kullanılmıştır.)

$$Y = \beta_0 + \beta_1 S + \beta_2 G + \varepsilon$$

MLR modellerinin tahmin performansını daha iyi anlayabilmek için, her bir modelin gerçek güneş radyasyonu değerleriyle tahmin edilen değerleri karşılaştırılmıştır.



Şekil 3. MLR Model çıktıları.

3.4. RNN Modeli ile Tahmin ve Değerlendirme

Bu çalışmada, İzmir Menemen bölgesine ait meteorolojik veriler kullanılarak RNN tabanlı güneş radyasyonu tahmin modelleri geliştirilmiştir. Veri seti, yıl, ay, gün, saat, sıcaklık, basınç, nem, rüzgâr yönü, rüzgâr hızı, yağış ve güneşlenme süresi gibi pek çok değişkeni içermektedir. RNN modelinin eğitiminde bağımsız değişkenler saatlik sıcaklık, saatlik, aktüel basınç, nispi nem, saatlik rüzgâr hızı, saatlik toplam yağış, saatlik güneşlenme süresi, saatlik küresel güneş radyasyonu olarak meteorolojik parametreler kullanılırken, bağımlı değişken olarak güneş radyasyonu tahmin edilmiştir. Deneysel çalışmalar kapsamında dört farklı RNN modeli geliştirilmiş ve her biri aşağıdaki şekilde temsil edilebilir.

M1 Modeli: (Tüm meteorolojik değişkenler giriş olarak kullanılmıştır.)

$$Y_1 = \text{RNN}(T, P, H, W, R, S, G)$$

M2 Modeli: (Nem, rüzgâr hızı, yağış ve güneş radyasyonu ile giriş yapılmıştır.)


$$Y_2 = \text{RNN}(H, W, R, G)$$

M3 Modeli: (Sıcaklık, nem, güneşlenme süresi ve güneş radyasyonu kullanılmıştır.)

$$Y_3 = \text{RNN}(T, H, S, G)$$

M4 Modeli: (Güneşlenme süresi ve küresel güneş radyasyonu kullanılmıştır.)

$$Y_4 = \text{RNN}(S, G)$$



Şekil 4. RNN Model Çıktıları

RNN modelleri ile elde edilen tahminlerin doğruluğunu daha iyi anlamak amacıyla, gerçek değerler ile tahmin edilen değerler grafiklerle karşılaştırmalı olarak sunulmuştur. Bu görselleştirme, hangi

modelin zamansal değişkenliği daha etkili bir şekilde yakaladığını değerlendirmek açısından önemlidir. Aşağıda, her modelin tahmin performansını gösteren grafikler Şekil 4'te yer almaktadır. Oluşturulan grafikler, zaman serisi boyunca tahmin edilen ve gerçek radyasyon değerlerini üst üste bindirerek sergilemekte ve böylece modelin doğruluğunu ile hata seviyelerini analiz etmeyi kolaylaştırmaktadır. Özellikle, tahmin edilen verilerin gerçek verilere ne ölçüde yakın olduğu ve sapmaların hangi bölgelerde yoğunlaştığı görsel olarak incelenebilir.

4. Performans Değerlendirme

Bu modellerin performansı ortalama karesel hata (MSE), ortalama mutlak hata (MAE) ve determinasyon katsayısı (R^2) gibi ölçütlerle değerlendirilmiştir. MLR ve RNN yöntemleri ile elde edilen sonuçları **Error! Reference source not found.**'te verilmiştir. Bu sonuçlar, MLR'nin M1 modelinin en düşük hata değerlerine ve en yüksek R^2 değerine sahip olduğu için en başarılı model olduğunu göstermektedir. Diğer yandan, MLR, M4 modeli, bağımsız değişken sayısının en az olduğu için en yüksek hata değerlerini üretmiştir. Tablo 3'teki sonuçlara göre, RNN, M1 modelinin en düşük hata değerlerine ve en yüksek R^2 skoruna sahip olduğu, dolayısıyla en iyi tahmin performansını sergilediği açıkça görülmektedir. Öte yandan, M4 modelinin en yüksek hata değerlerine ulaşması, bağımsız değişken sayısının azalmasının tahmin doğruluğunu olumsuz etkileyebileceğini göstermektedir.

Tablo 3 MLR ve RNN Performans Sonuçları

Model	Yöntem	MSE	MAE	R^2
M1	MLR	3.0944e+07	3643.7	0.88754
M1	RNN	2.4872e+07	2909.2	0.91481
M2	MLR	3.2341e+07	3761.2	0.88213
M2	RNN	2.6723e+07	2963.0	0.90847
M3	MLR	3.4102e+07	3894.5	0.87542
M3	RNN	2.7299e+07	3017.1	0.90650
M4	MLR	4.1023e+07	4210.9	0.85037
M4	RNN	3.5603e+07	3586.0	0.87806

MLR (Çoklu Doğrusal Regresyon) modeli sonuçlarına bakıldığında, M1 modelinin en düşük MSE (3.0944e+07) ve MAE (3643.7) değerlerine, en yüksek R^2 değerine (0.88754) sahip olduğu görülmektedir. M2, M3 ve M4 modellerinde bu değerlerin sırasıyla kötüleştiği, yani model başarısının azaldığı gözlemlenmektedir. Bu durum, MLR modelinde veri veya özellik karmaşıklığı arttıkça doğrusal yaklaşımın sınırlı kaldığını ve tahmin hatalarının büyüdüğünü göstermektedir. Genelde MLR modellerinin doğruluk oranları %85 ila %88 arasında kalmıştır.

RNN (Tekrarlayan Sinir Ağı) modeli ise MLR'ye kıyasla genel olarak daha iyi performans göstermiştir. M1 modelinde R^2 değeri 0.91481 ile en yüksek seviyeye ulaşmış, MSE ve MAE değerleri de en düşük seviyede gerçekleşmiştir (sırasıyla 2.4872e+07 ve 2909.2). RNN modellerinde R^2 değeri 0.87806 ile 0.91481 arasında değişmekte olup, bu değerler MLR'ye kıyasla daha yüksek doğruluk düzeylerini göstermektedir. Sonuç olarak, RNN modelleri zaman serisi gibi

ardışık verilerde daha başarılı performans sergilemiş ve doğrusal olmayan yapıları daha iyi modelleyebilmiştir.

Yapılan karşılaştırmalı çalışmalar, özellikle kısa vadeli tahminlerde RNN tabanlı modellerin daha düşük hata oranları (RMSE, MAE) ve daha yüksek belirleme katsayısı (R^2) gibi performans metrikleri açısından MLR'ye kıyasla üstün sonuçlar verdiğini ortaya koymuştur.

5. Sonuç

Bu çalışmada, güneş radyasyonu tahmininde Çok Değişkenli Doğrusal Regresyon (MLR) ile Yinelemeli Sinir Ağları (RNN) yöntemleri kullanılarak geliştirilen modellerin performansları, hata metrikleri (MSE, MAE) ve determinasyon katsayısı (R^2) gibi ölçütlerle değerlendirilmiştir.

Elde edilen bulgular, RNN tabanlı modellerin zaman serisi verilerinin dinamik yapısını daha iyi anlayarak, MLR modellere göre daha başarılı tahminler sağladığını ortaya koymaktadır. Özellikle RNN Model 1 (M1), en düşük hata değerleri (MSE: 2.4872e 07, MAE: 2909.2) ve en yüksek R^2 skoru (0.91481) ile en başarılı model olarak dikkat çekmiştir. MLR yönteminde ise en iyi performansı gösteren model M1 olmuş ve MSE: 3.0944e+07 ile R^2 : 0.88754 değerlerine ulaşarak tahmin doğruluğu sağlamıştır. Ancak, genel olarak MLR modelleri, RNN modellerine kıyasla daha yüksek hata oranları üretmiş ve zaman serisi analizinde daha düşük başarı göstermiştir.

Sonuç olarak, güneş radyasyonu tahmininde RNN modellerin daha isabetli ve güvenilir sonuçlar sağladığını göstermektedir. Bu bağlamda, yenilenebilir enerji sistemlerinin daha verimli kullanılması amacıyla, uzun kısa süreli bellek (LSTM) ve kapalı döngü RNN GRU gibi daha gelişmiş derin öğrenme mimarilerinin uygulanması önerilmektedir. Gelecek araştırmalar, farklı coğrafi bölgelerdeki meteorolojik veriler kullanarak model çeşitliliğini artırabilir ve daha uzun vadeli tahminlerle enerji yönetiminde etkili karar destek sistemlerinin geliştirilmesine katkıda bulunabilir.

Kaynakça

- [1] T. Demirgöl, V. Demir, and M. F. Sevimli, “Farklı makine öğrenmesi yaklaşımları ile Türkiye ’ nin solar radyasyon tahmini Türkiye ’ s solar radiation forecasting with different machine learning approaches,” vol. 9, no. 1, pp. 106–122, 2024.
- [2] S. UĞUZ, O. ORAL, and N. ÇAĞLAYAN, “Estimation of Energy to be Obtained from PV Power Plants Using Machine Learning Methods,” *Uluslararası Muhendis. Arastirma ve Gelistirme Derg.*, pp. 769–779, 2019, doi: 10.29137/umagd.514933.
- [3] C. Voyant *et al.*, “Machine learning methods for solar radiation forecasting: A review,” *Renew. Energy*, vol. 105, pp. 569–582, 2017, doi: 10.1016/j.renene.2016.12.095.
- [4] Ş. EBREN KARA and R. ŞAMLI, “Yazılım Projelerinin Maliyet Tahmini için WEKA’da Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Analizi,” *Eur. J. Sci. Technol.*, no. 23, pp. 415–426, 2021, doi: 10.31590/ejosat.877296.

- [5] Y. Berus and Y. Benteşen Yakut, “Derin Öğrenme (1D-CNN, RNN, LSTM, BiLSTM) ile Enerji Tüketim Tahmini: Diyarbakır AVM Örneği,” *DÜMF Mühendislik Derg.*, vol. 2, pp. 311–322, 2024, doi: 10.24012/dumf.1415055.
- [6] Z. Pang, F. Niu, and Z. O’Neill, “Solar radiation prediction using recurrent neural network and artificial neural network: A case study with comparisons,” *Renew. Energy*, vol. 156, pp. 279–289, 2020, doi: 10.1016/j.renene.2020.04.042.
- [7] A. ALAN and M. KARABATAK, “Veri Seti - Sınıflandırma İlişkisinde Performansa Etki Eden Faktörlerin Değerlendirilmesi,” *Fırat Üniversitesi Mühendislik Bilim. Derg.*, vol. 32, no. 2, pp. 531–540, 2020, doi: 10.35234/fumbd.738007.
- [8] Ö. Ali KARAMAN and Y. Bektaş, “Makine Öğrenmesi ve Optimizasyon Yöntemleri ile Uzun Dönem Elektrik Enerjisi Tahmini: Türkiye Örneği,” vol. 5, no. 2, pp. 285–292, 2023.
- [9] E. UĞURLU, “Türkiye Enerji Piyasasının Çok Değişkenli Doğrusal Regresyon Analizi ile incelenmesi,” 2011.
- [10] Y. Ve and B. D. R. Uygulama, “REGRESYON ANALİZİNDE DOĞRUSALA DÖNÜŞTÜRME YÖNTEMLERİ VE BDR UYGULAMA Selahattin YAVUZ (*),” *Test*, 2006.
- [11] I. Siraj and Á. Drégelyi-Kiss, “Empirical comparison of FDM additive manufacturing process parameters by application grey relational analysis and multi-linear regression,” *Int. J. Adv. Manuf. Technol.*, pp. 2861–2876, 2025, doi: 10.1007/s00170-025-15688-4.
- [12] 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*, vol. 78, pp. 247–256, 2014, doi: 10.1016/j.energy.2014.10.012.
- [13] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [14] F. ÖZCAN, “DERİN YAPAY SİNİR AĞLARI İLE ELEKTRİK TÜKETİM TAHMİNİ,” 2022.
- [15] F. N. AYDIN and K. A. KABASAKAL, “Regresyon Ağaçları ve Çoklu Doğrusal Regresyon Analizlerinin PISA 2022 Matematik Okuryazarlığı Becerisini Yordama Performanslarının İncelenmesi,” vol. 3, no. 1, pp. 1069–1091, 2024.