



## Short-term forecasting of solar irradiance and temperature using deep learning models with multiple inputs and multiple outputs

Kübra Kaysal<sup>1\*</sup>, Fatih Onur Hocaoğlu<sup>2</sup>, Nihat Öztürk<sup>3</sup>

<sup>1</sup>Department of Electrical and Energy, Afyon Vocational School, Afyon Kocatepe University, 03200, Afyonkarahisar, Türkiye

<sup>2</sup>Department of Electrical Engineering, Engineering of Faculty, Afyon Kocatepe University, 03200, Afyonkarahisar, Türkiye

<sup>3</sup>Department of Electrical and Electronics Engineering, Faculty of Technology, Gazi University, 06560, Ankara, Türkiye

### Highlights:

- Examining the effect of multivariate inputs on bivariate outputs for short-term forecasts
- The original and hybrid deep learning model combining CNN and BILSTM for solar irradiance and temperature
- Comparison of the performance of different deep Learning models and their hybrid configurations

### Keywords:

- Solar Radiation Estimation
- Temperature Estimation
- Deep Learning
- Bidirectional Long-Short Term Memory
- Multi-Input/Multivariate Output Models

### Article Info:

Research Article  
Received: 15.08.2025  
Accepted: 28.12.2025

### DOI:

10.17341/gazimmfd.1533969

### Correspondence:

Author: Kübra Kaysal  
e-mail: kkaysal@aku.edu.tr  
phone: +90 272 218 2993

### Graphical/Tabular Abstract

In this study, the impact of multivariate inputs on bivariate outputs for short-term forecasts was analyzed, with a particular focus on the effects of meteorological changes on a planned solar power plant in the region. A hybrid deep learning method is proposed to enhance the prediction of solar radiation intensity and temperature. In this model, a CNN architecture was employed to extract significant features from the data, while complex temporal structures were captured using the BILSTM architecture, which effectively learns dependencies both from past to future and future to past. Given that the model incorporates multiple meteorological inputs and two outputs, it is classified as a multi-input-multiple output model. The flow chart of the proposed hybrid deep learning model (M/CNN-BILSTM) is presented in Figure A. Comparative experimental results of the hybrid deep learning model have demonstrated promising and successful outcomes.

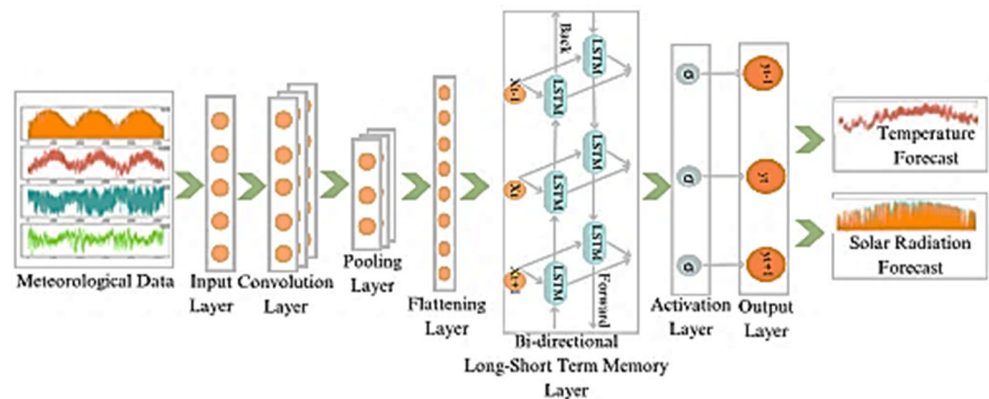


Figure A. M/CNN-BILSTM model flow chart

**Purpose:** The aim of this study is to obtain optimal and reliable short-term predictions of solar radiation and temperature for the Afyonkarahisar region by employing various deep learning models and their hybrid combinations. The study also seeks to comprehensively examine the effects of different meteorological inputs on bivariate outputs, with the goal of enhancing the efficiency of solar power plants and improving the accuracy of economic and environmental analyses in this field.

**Theory and Methods:** The intermittent nature of solar radiation poses challenges for many applications, making accurate estimation of solar radiation and temperature essential for predicting photovoltaic power output. A hybrid model combining Convolutional Neural Networks (CNN) and Bidirectional Long Short-Term Memory (BILSTM) networks is proposed to examine the impact of multivariate inputs on bivariate outputs (solar radiation and temperature) and to predict these variables. The model's performance was compared with other deep learning models and their hybrid combinations.

**Results:** The success of the proposed hybrid model was evaluated using statistical criteria such as RMSE, MAE, NRMSE, and  $R^2$ . The results indicated that, according to all statistical evaluation criteria, the proposed hybrid model outperformed the other benchmark models, making it the most successful prediction model.

**Conclusion:** In this study, a hybrid model combining CNN and BILSTM with multi-input and multi-output capabilities is proposed for temperature and solar radiation prediction. The results demonstrate that the proposed model outperforms other deep learning models and their hybrid combinations across all statistical metrics, indicating its effectiveness in irradiance and temperature prediction.



## Çok girdili-çok değişkenli çıktıya sahip derin öğrenme modelleri ile kısa vadeli güneş ışınım şiddeti ve sıcaklık tahmini

Kübra Kaysal<sup>1\*</sup>, Fatih Onur Hocaoglu<sup>2</sup>, Nihat Öztürk<sup>3</sup>

<sup>1</sup>Afyon Kocatepe Üniversitesi, Afyon Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, 03200, Afyonkarahisar, Türkiye

<sup>2</sup>Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, 03200, Afyonkarahisar, Türkiye

<sup>3</sup>Gazi Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 06560, Ankara, Türkiye

### Ö N E Ç İ K A N L A R

- Kısa vadeli tahminler için çok değişkenli girdilerin iki değişkenli çıktılara etkisinin incelenmesi
- Güneş ışınımı ve sıcaklık tahmini için CNN ve BiLSTM tabanlı özgün hibrit derin öğrenme modeli.
- Farklı derin öğrenme modelleri ve onların hibrit oluşumlarının performanslarının karşılaştırılması

### Makale Bilgileri

Araştırma Makalesi

Geliş: 15.08.2025

Kabul: 28.12.2025

DOI:

10.17341/gazimmfd.1533969

**Anahtar Kelimeler:**

Işınım şiddeti tahmini,  
sıcaklık tahmini,  
derin öğrenme, çift yönlü  
uzun- kısa süreli bellek, çok  
girdili-çok değişkenli çıkış

### ÖZ

Güneş ışınımının kesikli ve dalgalı yapısı çoğu uygulama için ciddi sınırlamalar oluşturur. Güneş ışınım şiddetinin doğru tahmini, bir fotovoltaiik güç sisteminin çıkış gücünün tahmin edilmesinde önemli bir faktördür. Bu çalışmada, kısa dönemli tahminler için çok değişkenli girdilerin iki değişkenli çıktılara etkisi incelenmiş ve bir bölgeye kurulması planlanan güneş enerji santrali için meteorolojik değişimlerin etkileri araştırılmıştır. Ayrıca çeşitli derin öğrenme modelleri ve onların hibrit kombinasyonlarının güneş ışınım şiddeti ve sıcaklık tahmini için başarıları kıyaslanmıştır. M/CNN-BiLSTM\_II modeli diğer modellere kıyasla üç girdi parametresi sıcaklık, ışınım şiddeti ve nem için hem sıcaklık hem de ışınım şiddeti tahmininde en iyi performansı sergilemiştir. Modellerin performansı için RMSE, MAE, NRMSE, SMAPE ve R<sup>2</sup> metrikleri kullanılmıştır. Işınım şiddeti için bu metrikler sırasıyla 71,21 W/m<sup>2</sup> (RMSE), 35,42 W/m<sup>2</sup> (MAE), %6,52 (NRMSE), %14,87 (SMAPE) ve %94,78 (R<sup>2</sup>) olarak hesaplanmıştır. Sıcaklık değerleri için ise RMSE 0,76°C, MAE 0,54°C, NRMSE %1,59, SMAPE %12,14 ve R<sup>2</sup> %99,23 olarak elde edilmiştir.

## Short-term forecasting of solar irradiance and temperature using deep learning models with multiple inputs and multiple outputs

### H I G H L I G H T S

- Examining the effect of multivariate inputs on bivariate outputs for short-term forecasts
- The original and hybrid deep learning model combining CNN and BiLSTM for solar irradiance and temperature
- Comparison of the performance of different deep Learning models and their hybrid configurations

### Article Info

Research Article

Received: 15.08.2025

Accepted: 28.12.2025

DOI:

10.17341/gazimmfd.1533969

**Keywords:**

Solar radiation estimation,  
temperature estimation,  
deep learning, bidirectional  
long-short term memory,  
multi-input-multivariate  
output models

### ABSTRACT

The intermittent and fluctuating nature of solar radiation poses significant limitations for many applications. Accurate estimation of solar radiation is a crucial factor in predicting the output power of a photovoltaic system. In this study, the effects of multivariate inputs on bivariate outputs for short-term forecasts were examined, and the impact of meteorological changes on a solar power plant planned for a specific region was investigated. Additionally, the performance of various deep learning models and their hybrid combinations for predicting solar radiation and temperature was compared. Compared to other models, the M/CNN-BiLSTM\_II model demonstrated the best performance in estimating both temperature and radiation intensity using the three input parameters: temperature, solar radiation, and humidity. The performance of the models was evaluated using RMSE, MAE, NRMSE, SMAPE, and R<sup>2</sup> metrics. For solar radiation, these metrics were calculated as 71,21 W/m<sup>2</sup> (RMSE), 35,42 W/m<sup>2</sup> (MAE), %6,52 (NRMSE), %14,87 (SMAPE) and %94,78 (R<sup>2</sup>), respectively. For temperature values, RMSE was obtained as RMSE 0,76°C, MAE 0,54°C, NRMSE %1,59, SMAPE %12,14 and R<sup>2</sup> %99,23.

## 1. Giriş (Introduction)

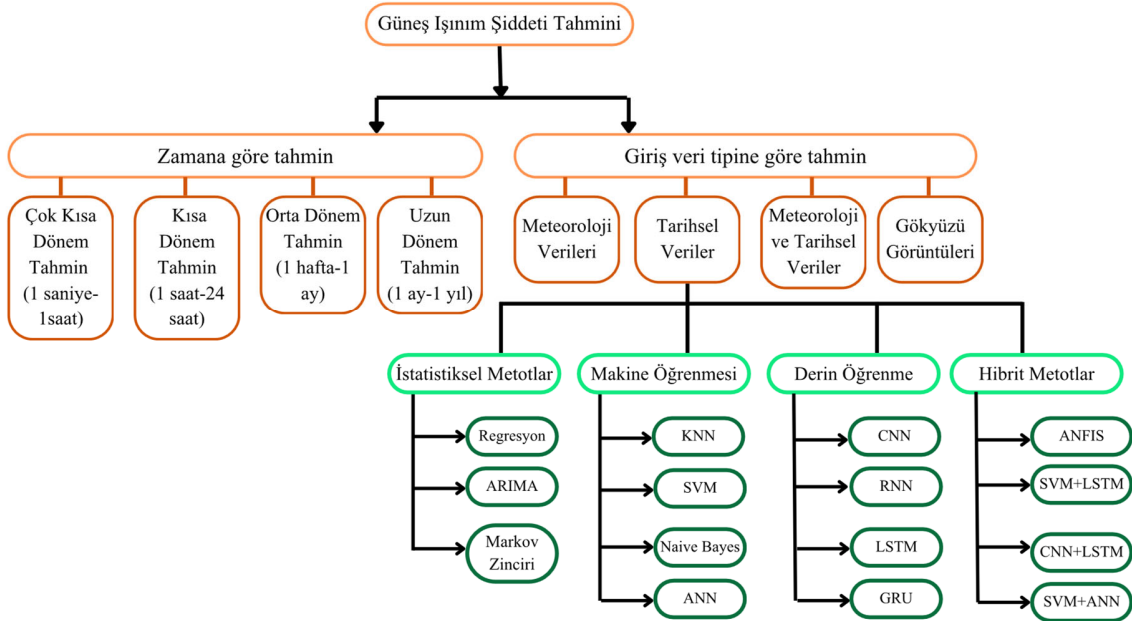
Nüfus artışı, modern toplumların büyümesi, teknolojik gelişmeler ve sanayi ihtiyaçlarının karşılanması gibi faktörler, enerji kaynaklarına olan bağımlılığı artırmaktadır. Fosil yakıtların azalması ve çevreye olan sera gazı etkileri, artan enerji talebini karşılamak için alternatif enerji kaynaklarına yönelimi teşvik etmektedir. Genel olarak, rüzgarla birlikte güneş enerjisi, yenilenebilir enerjinin küresel elektrik üretimindeki payının artmasına önemli ölçüde katkıda bulunmaktadır. 2022 yılında küresel enerjinin %12'si rüzgâr ve güneş enerjisi ile birlikte sağlanırken, güneş enerjisi, temiz kaynaklardan elde edilen küresel elektriğin %10 'u gibi önemli bir kısmına katkı sağlamıştır. Bu doğrultuda, güneş enerjisi ile elektrik üretiminin küresel enerji üretimindeki payının giderek artması beklenmektedir [1, 2].

Bir fotovoltaik panelin ürettiği elektrik miktarı, büyük ölçüde güneş ışınım şiddetine bağlıdır. Gün içinde yaşanan sıcaklık değişimleri ile birlikte ışınım değerinin rasgele dalgalanmaları ve belirsiz özellikleri, panel güç çıkışında önemli değişikliklere neden olmaktadır. Bu değişimler, şebeke frekansında dalgalanmalara, voltaj değişimlerine ve aşırı durumlarda elektrik kesintilerine neden olarak enerji kalitesini düşürmekte ve güvenilirliği azaltmaktadır. Ayrıca, değişken bir çıkış gücü, enerjinin sürekliliğini sağlamak için büyük ölçekli enerji depolama sistemlerine ihtiyacı artırarak maliyetleri yükseltebilir. Bu etkileri minimize etmek için doğru güneş enerjisi tahminleri, yatırımcılar ve müşteriler için etkili enerji yönetimi, optimum maliyet, güvenilirlik ve üretim dengesi sağlanması açısından kritik bir öneme sahiptir [3]. Güneş enerjisi ile ilgili tahminler, zamana ve giriş veri tipine göre iki ana başlıkta incelenmektedir. Şekil 1'de verilen sınıflandırma grafiğine göre tarihsel veriler başlığı altında incelenen güneş ışınım tahmini yöntemleri ise istatistiksel yöntemler, makine öğrenmesi, derin öğrenme ve hibrit yöntemler olarak sınıflandırılmaktadır [4].

Belirli bir noktadaki ışınım şiddeti tahmininin temelini meteorolojik ve tarihsel veriler oluşturmaktadır. Beklenen ışınım şiddetini kabul edilebilir bir doğrulukta tahmin edebilen ilk modeller yirminci yüzyılda geliştirilmeye başlanmıştır. Bu modellerden en iyi bilinenleri

ampirik modeller olmuştur. Basit yapılarına rağmen bu modellerin en büyük kısıtı, ışınım şiddeti verilerinin doğrusal olduğu varsayımına dayalı olmalarıdır. Halbuki, atmosferik sistem oldukça değişken bir yapıya sahiptir ve bu durum modellerin tahmin başarısını etkilemektedir [5]. Bu sınırlamanın üstesinden gelmek için ışınım şiddeti tahmini konusunda çeşitli araştırmalar gerçekleştirilmiştir. Bhardwaj vd. [6] güneş ışınım şiddetini tahmin ettiği bir çalışmada gizli Markov modeli ve genelleştirilmiş bulanık modelin bir kombinasyonunu kullanmışlardır. Farklı meteorolojik parametrelerin kullanıldığı çalışmada kısa dönem ışınım şiddeti tahmininde başarılı sonuçlar elde edilmiştir. İstatistiksel tahmin modellerinin kullanıldığı bir diğer çalışmada Sharadga vd. [7] büyük ölçekli bir fotovoltaik (PV) tesisin çıkış gücünü tahmin etmek için Oto regresif hareketli ortalama (Autoregressive Moving Average-ARMA), Otoresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) ve Mevsimsel Otoresif Entegre Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average-SARIMA) gibi modellerin performansını, Yapay sinir ağları (Artificial Neural Network-ANN) ile karşılaştırmışlardır. Sonuçlar, ANN modelinin, istatistiksel yöntemlere göre daha yüksek başarı ve daha az hesaplama süresi gerektiğini göstermiştir. Güneş ışınım tahmininde makine öğrenmesi yöntemlerinin kullanıldığı çalışmalar da mevcuttur. Ertürk vd. [8] Türkiye'nin farklı iklim özelliklerine sahip dört ili için ANN modeli geliştirmişlerdir. Güneş ışınımı tahmini için 2012-2021 yıllarına ait meteorolojik ve coğrafi parametrelere ait veriler kullanılmıştır. Kullanılan verilerin %50 'si eğitim, %25'i doğrulama ve %25 'i ise test için kullanılmıştır. Farklı iklim koşullarında, ANN modelinin doğruya yakın sonuçlar verdiği görülmüştür. Arslan vd. [9] Mersin ili için bir yıllık ölçülen çeşitli meteorolojik verileri kullanarak, günlük güneş ışınım tahminini ANN ile modellemiştir. Model sonucu, belirlilik katsayısı ( $R^2$ ) 0,75 ve ortalama mutlak sapma (MAPE) %27,67 olarak hesaplanmıştır.

Son zamanlarda derin öğrenme tabanlı modeller, ham verilerden karmaşık örüntüleri öğrenme konusunda üstün yetenekleri sayesinde, güneş ışınım tahmininde büyük ilgi görmeye başlamıştır. Elsaraiti ve Merabet [10] derin öğrenme yöntemlerinden, Uzun Kısa Süreli Bellek (Long Short-Term Memory-LSTM) ve Çok Katmanlı



Şekil 1. Güneş ışınım şiddeti tahmin yaklaşımları ve yöntemleri sınıflandırılması (Classification of approaches and methods for solar radiation estimation)

Algılayıcı (Multilayer Perceptron-MLP) modellerini, güneş ışınım şiddeti tahmini için kullanmış ve performanslarını karşılaştırmışlardır. Model için kullanılan veriler, Kanada'nın Nova Scotia eyaletinden elde edilmiş ve beşer dakikalık periyotlarla ölçülmüştür. LSTM modelinin tahmin performansının, MLP algoritmasına göre daha etkili bir performans sergilediği gözlenmiştir. Literatüre katkısı olan bir diğer çalışmada Gupta vd. [11] her biri farklı güneş ışınım şiddeti özelliklerine sahip olan Rajasthan şehrinin dört farklı bölgesi için derin öğrenme modellerinden oluşan hibrit bir yöntem önermişlerdir. Modeller arasında Evrişimli Sinir Ağı (Convolutional Neural Network-CNN), Kapı Özyinelemeli Geçitler (Gated Recurrent Units-GRU) ve LSTM yapıları kullanılmıştır. Her bölge için CNN-LSTM-GRU hibrit modeli başarılı sonuçlar vermiştir. Michael vd. [12] saatlik güneş ışınım şiddeti tahmini için Çift Yönlü Uzun Kısa Süreli Bellek (Bi-Directional Long Short-Term Memory-BiLSTM) ve GRU modellerinin hibrit bir yapısını sunmuşlardır. Çalışmada Brezilya'ya ait çeşitli meteorolojik veriler modellere girdi olarak sunulmuştur. Veriler, eğitim ve test veri setlerine göre %50-%50 oranında ayrılmıştır. Modellerin hiperparametre ayarları Bayes optimizasyonu kullanılarak belirlenmiştir. BiLSTM-GRU hibrit yapısı diğer derin öğrenme ve makine öğrenme modellerine kıyasla daha az hata, yüksek doğruluk ve daha az karmaşıklık göstermiştir. Bir başka çalışmada Bakht vd. [13] fotovoltaiik güç çıkış tahmini için otomatik makine öğrenmesi modelleri kullanmıştır. Çalışmada çevresel faktörlerin etkileri de araştırılmıştır. Çeşitli yöntemlerin karşılaştırıldığı çalışmada Ekstra Ağaç, Rastgele Orman, XGBoost ve Karar Ağacı modellerinin başarıları oldukça yüksek hesaplanmıştır. Mohanty vd. [14] tarafından vektör otoregresyon, vektör otoregresif hareketli ortalama, vektör hata düzeltme modeli, ortalama varyans düzenlemesi, bayes doğrusal regresyon ve ışık gradyanı artırma makinesi (LGBM) gibi çeşitli çok değişkenli istatistiksel modellerin performansı, güneş panelinin çıkış gücünü tahmin etmek için incelenmiştir. LGBM modeli başarılı sonuçlar göstermiştir.

Bu çalışmada, Afyonkarahisar için çok adımlı ve çok değişkenli çıktılara sahip, derin öğrenme yöntemlerinden CNN, LSTM, GRU, BiLSTM ve yığınlanmış kapılı tekrarlayan birimden (Stacked Gated Recurrent Unit-SGRU) oluşan yapılar ve bu yapıların hibrit modelleri kullanılarak kısa dönemli güneş ışınım şiddeti ve sıcaklık tahminleri gerçekleştirilmiştir. Çalışmada, bir güneş enerji santralinin belirli bir bölgeye en uygun ve güvenilir şekilde kurulması amacıyla modeller;

a) 2 giriş-2 çıkış, b) 3 giriş-2 çıkış, olacak şekilde iki farklı senaryo için gerçekleştirilmiştir. Çalışmada kullanılan veriler, Meteoroloji Bölge Müdürlüğünden (MBM) alınan 2019, 2020 ve 2021 yıllarına ait üç yıllık ve saatlik frekansta ölçülmüş güneş ışınımı, basınç, nem ve sıcaklık verileridir. Üç yıllık toplam 26280 adet verinin %70'i eğitim, %30'u ise test amaçlı kullanılmış ve on saat önceki veriler ile bir saat sonrası tahmin edilmeye çalışılmıştır. Modellerin değerlendirme parametreleri karşılaştırıldığında üç girişli M/CNN-BiLSTM\_II modeli diğer modellere göre en iyi performansı sergilediği görülmüştür. Ayrıca çalışmada meteorolojik verilerin tahminler üzerindeki etkisi incelenmiş ve bağlı nemin özellikle sıcaklık tahminini önemli ölçüde etkilediği sonucuna varılmıştır. Sonuç olarak, literatürde genellikle çok girdili modellerin yalnızca ışınım şiddeti tahminine odaklandığı görülmektedir. Bu çalışmanın temel ayırt edici özelliği ise, kısa dönemli tahminler için çok değişkenli meteorolojik girdilerin iki değişkenli çıktılar üzerindeki etkilerini kapsamlı bir şekilde incelemesidir. Bu yaklaşım, daha doğru sonuçlara ulaşılmasını sağlayarak, ekonomik ve çevresel analizlerin daha güvenilir ve kapsamlı bir şekilde gerçekleştirilmesine katkıda bulunmaktadır.

Çalışmanın literatüre katkıları şöyle sıralanabilir;

1-Çeşitli derin öğrenme modellerinin ve onların hibrit kombinasyonlarının performanslarının karşılaştırılması,

- 2- Kısa vadeli tahmin, anlık enerji dalgalanmalarında şebeke ve yük tarafında denge sağlanmasına yardımcı olarak, enerji yönetimine katkı sağlamaktadır.
- 3- Güneş ışınım şiddeti ve sıcaklık parametreleri, güneş enerji santrallerinin optimal yerleşimi için oldukça önemlidir. Çalışmada çok çıktılı bir tahmin modeli geliştirilmiştir. Böylece bir bölgeye kurulması planlanan güneş enerji santralinin verimliliği artırılabilir ve yatırımcılara etkin bir planlama fırsatı sunulabilir.
- 4- Farklı meteorolojik değişkenlerin tahmin üzerindeki etkileri detaylı bir şekilde incelenmiştir. Böylece bir fotovoltaiik panelin enerji üretimi tahmininde hangi değişkenlerin daha kritik rol oynadığı belirlenmiş olacaktır.

Makale yedi ana başlıktan oluşmakta olup, Bölüm 2'de derin öğrenme modellerine ait detaylar verilmiştir. Bölüm 3'te performans metriklerinden bahsedilmiştir. Bölüm 4'te güneş ışınım şiddeti, kullanılan veri seti ve veri ön işleme hakkında bilgi verilmiştir. Bölüm 5'te M/CNN-BiLSTM\_II modelinden elde edilen tahmin değerleri, karşılaştırma grafikleri ve modellerin performansları değerlendirilmiştir. Bölüm 6'da çalışmadan elde edilen sonuçlar verilmiştir. Son olarak Bölüm 7'de ise tartışmalar verilmiştir.

## 2. Metodoloji (Methodology)

### 2.1. Evrişimli Sinir Ağları (Convolutional Neural Network-CNN)

CNN'ler görüntü tanıma ve doğal dil işleme gibi birçok alanda başarılı sonuçlar veren ileri beslemeli bir sinir ağı modelidir. Ayrıca bu modeller, zaman serisi verilerinde yerel bağımlılıkları ve kısa vadeli desenleri yakalamada oldukça başarılıdır. Kullandığı filtreler aracılığıyla zaman serisi verisinden özellikler çıkarır ve bu özellikleri kullanarak tahminlerde bulunur. Bu yöntem, verideki gürültüyü azaltırken anlamlı özelliklerin öne çıkmasını sağlar [15]. CNN mimarisinin çok çeşitli varyantları olmasına rağmen, temel bileşenleri genel olarak; evrişimli katman, havuzlama katmanı ve tam bağlantılı katmandır [16, 17]. Evrişim işlemi sırasında, her filtre çıktısı bir bias değeri eklenir ve ardından bir aktivasyon fonksiyonu uygulanır. Bu işlem, modelin doğrusal olmayan ilişkilerini yakalayıp veri içerisindeki özelliklerin çıkarılmasını sağlar. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında ReLU, tanh ve sigmoid bulunur [18]. Evrişim işlemi Eş. 1'de verildiği gibi hesaplanır.

$$O(t) = f\left(\sum_{j=0}^{l-1} x_{t+j} \cdot l_j + b\right) \quad (1)$$


Eş. 1'de  $O(t)$ , evrişim işleminden sonra  $t$  anındaki çıktı dizisini,  $f$  kullanılan aktivasyon fonksiyonunu,  $x_{t+j}$  giriş vektörünün  $t+j$  anındaki değeri,  $l_j$  filtrenin  $j$  indeksindeki ağırlık değerini ve  $b$  bias değerini ifade etmektedir. CNN mimarisindeki bir diğer katman olan havuzlama katmanı ise veri boyutunu azaltarak modelin hesaplama yükünü düşürür. Bu sayede modelin performansı artırılarak, veriden daha anlamlı özellikler elde edilmektedir. Tam bağlantı katmanı ise diğer katmanlardan gelen özelliklerin birleştirilip tek bir vektör elde edilmesini sağlamaktadır. CNN algoritmasının mimari yapısı grafiksel olarak Şekil 2'de verilmiştir.

### 2.2. Uzun-Kısa Süreli Bellek Ağları ve Çift Yönlü Uzun-Kısa Süreli Bellek Ağları

(Long Short-Term Memory- LSTM and Bi-Directional Long Short-Term Memory- BiLSTM)

LSTM mimarileri, Tekrarlayan Sinir Ağlarındaki (RNN) kaybolan gradyan problemine bir çözüm olarak geliştirilmiştir. Zaman serileri, kronolojik sırayla indekslenen belli bir dizi yapısıdır. LSTM modeli

ise dizi problemlerinde sıralı değişkenleri işleyebilme yeteneğine sahiptir. Bu özellikleri onları zaman serileri problemlerinin çözümünde avantajlı hale getirir. Bir RNN yapısı ile kıyaslandığında LSTM'in iç yapıları daha karmaşıktır. LSTM yapıları bilgilerin saklanabileceği, yazılabileceği, okunabileceği ve ezberleme sürecini kontrol eden çeşitli yapılardan oluşmaktadır. Bir LSTM yapısında hücre durumu, giriş kapısı, unutmaya kapısı ve çıkış kapısı olmak üzere dört adet sinir ağı katmanı bulunmaktadır.



Şekil 2. CNN mimari yapısı (CNN architectural structure)

$$i_t = \sigma(W_i [h_{t-1}, x_t] + b_i) \quad (2)$$

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tanh(W_c [h_{t-1}, x_t] + b_c) \quad (4)$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (5)$$

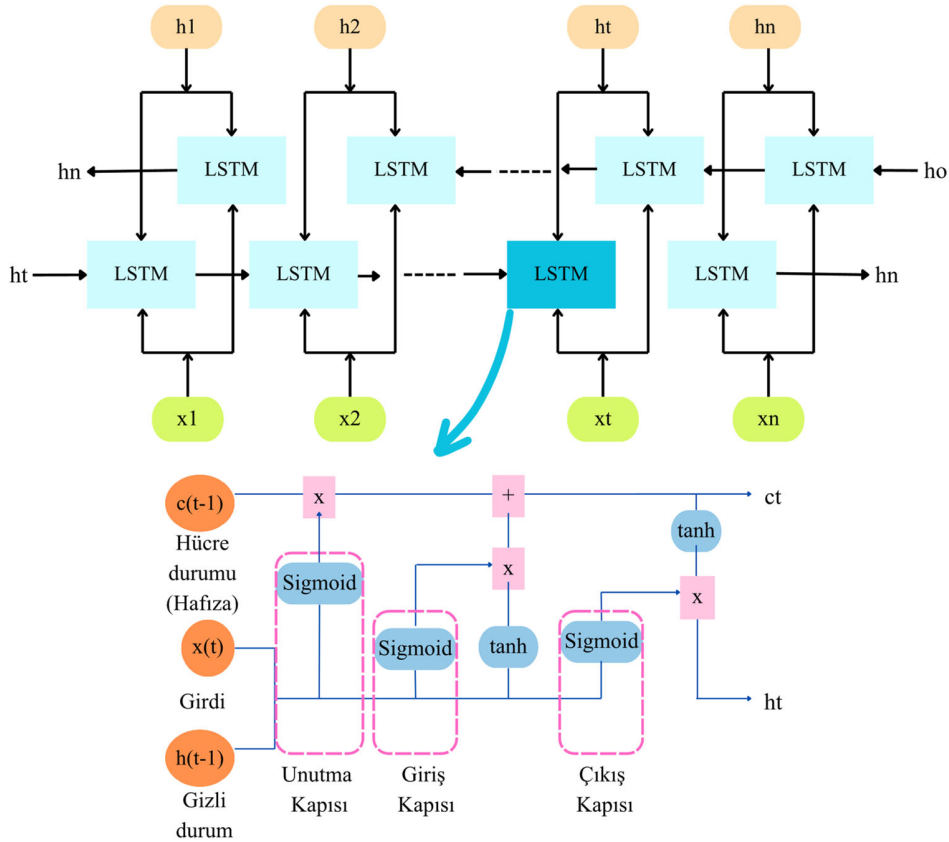
$$h_t = o_t * \tanh(C_t) \quad (6)$$

Bir LSTM mimarisinin katmanlarının hesaplanması Eş. 2 ile Eş. 6 arasında gösterilmiştir. Eşitliklerde,  $W_i, W_f, W_c, W_o$  ağırlık matrisleri,  $\sigma$  sigmoid aktivasyon fonksiyonu,  $b_i, b_f, b_c$  ve  $b_o$  her bir kapının bias ağırlıklarıdır.  $f_t$  unutmaya kapısı,  $o_t$  çıkış kapısı,  $C_t$  ise hücre çıkışlarını temsil eder [19, 20]. BiLSTM modeli, klasik LSTM modellerinden farklı olarak, veriyi hem ileri hem de geri yönde işler. Modelin hem geçmiş hem de gelecek bilgileri kullanarak iki yönlü bilgi akışı yapabilme özellikleri sayesinde, veriden daha kapsamlı ve doğru tahminler yapılmasını sağlar. BiLSTM algoritmasının mimari yapısı grafiksel olarak Şekil 3'te verilmiştir.

### 2.3. Kapılı Tekrarlayan Birim ve Yığınlanmış Kapılı Tekrarlayan Birim (Gated Recurrent Unit-GRU and Stacked Gated Recurrent Unit-SGRU)

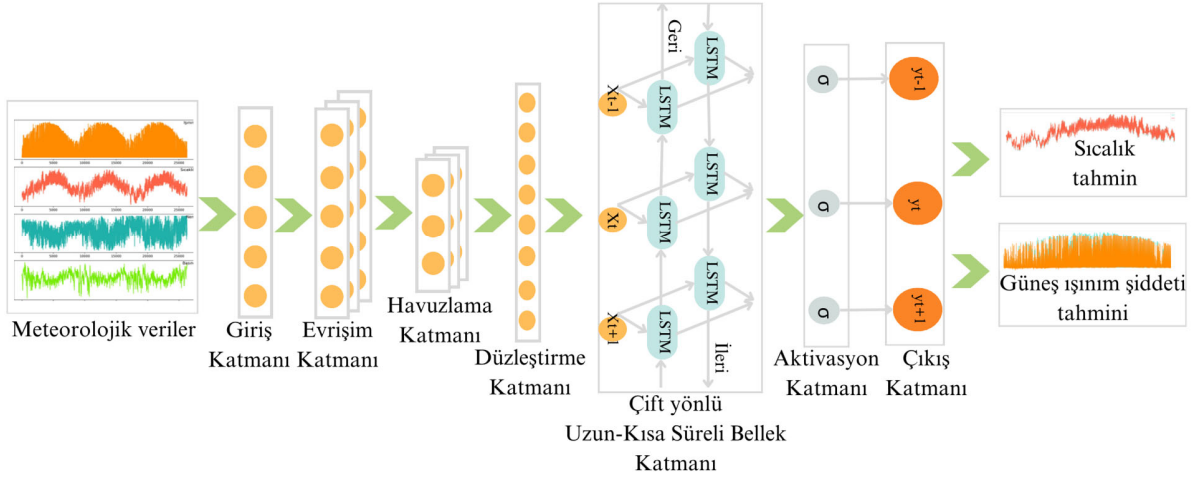
GRU mimarisi ise LSTM mimarisine benzerdir. LSTM'deki üç kapıya kıyasla sadece iki kapı içerdiğinden, genel olarak daha az hesaplama gerektirir. Bu özellikleri sayesinde daha hızlı eğitilirler. Hücre durumu, sıfırlama kapısı ve güncelleme kapısı içerir [21, 22]. Bir GRU mimarisinin katmanlarının hesaplanması Eş. 7 ile Eş. 9 arasında gösterilmiştir. Verilen eşitliklerde  $x_t$  giriş değeri,  $h_t$  çıkış,  $z_t$  güncelleme kapısı,  $r_t$  sıfırlama kapısı,  $W, U, b$  ise öğrenme parametreleridir.

$$Z_t = \sigma_g (W_z x_t + U_z h_{t-1} + b_z) \quad (7)$$



Şekil 3. BiLSTM mimari yapısı (BiLSTM architectural structure)





Şekil 5. M/CNN-BİLSTM modeli akış şeması (Proposed M/CNN-BILSTM model flow chart)

bileşenlere ayrılır. GHI, atmosferdeki güneş ışığının dünya üzerinde eşit olarak dağıldığı bir olguyu tanımlar. PV sistemlerinin kurulumunda önemli bir parametredir. GHI değeri Eş. 15 ile ifade edilir [31].

$$GHI = DNI * \cos\theta + DHI \quad (15)$$

Eş. 15'te  $\theta$  güneşin Zenit açısıdır ve üç boyutlu bir koordinat sisteminde tepe noktası, yatay düzleme dik olan eksenidir. Zenit açısı Eş. 16'daki gibi hesaplanır [31].

$$\cos\theta = \sin\delta\sin\varphi + \cos\delta\cos\varphi\cos\omega \quad (16)$$

Eş. 16'da  $\delta$  güneşin eğimini,  $\omega$  saat açısını ve  $\varphi$  enlemi ifade eder. Bu açıklamada yerel saat, güneşin bir gözlem noktasındaki yıllık hareketinin belirli bir anının açısal ölçüsü olarak tanımlanmaktadır. Güneş sapması, yılın farklı dönemlerinde güneşin gözlem noktasındaki görünen yükselme açısının değişimini ifade eder ve bu değişim coğrafi konumdan bağımsızdır. Bu değer, yılın en uzun günü olan 21 Haziran'da en yüksek değerine  $23^{\circ}27'$  ulaşırken, en kısa günü olan 22 Aralık'ta en düşük değeri olan  $-23^{\circ}27'$ ye düşmektedir.

#### 4.2. Veri Seti (Data Set)

Türkiye, güneş kuşağında yer alan coğrafi konumu sayesinde güneş enerjisi potansiyeli yüksek bir ülkedir. Türkiye Meteoroloji Genel Müdürlüğü'nün 2023 yılı verilerine göre, Türkiye'nin yıllık toplam güneşlenme süresi ortalama 2741 saat, yıllık ortalama güneş ışınım şiddeti  $1578,1 \text{ kWh/m}^2$  ve yıllık ortalama sıcaklık değeri  $14,3^{\circ}\text{C}$  olarak ölçülmüştür [32].

Bu çalışma,  $38^{\circ} 45' 27''$  kuzey enlemi ve  $30^{\circ} 32' 14''$  doğu boylamında yer alan Afyonkarahisar ili için gerçekleştirilmiştir. Afyonkarahisar, yıllık ortalama  $1600-1650 \text{ kWh/m}^2$  güneş ışınım şiddeti, 6,7 saat güneşlenme süresi ve yıllık ortalama  $11,3^{\circ}\text{C}$  sıcaklık değeri ile Türkiye ortalamasına oldukça yakın değerlere sahiptir [32-33]. Enerji yatırımcıları için Afyonkarahisar ilinin güneş radyasyonunun kapsamlı bir şekilde incelenmesi, sadece bölgenin enerji potansiyelinin belirlenmesi için değil, aynı zamanda yenilenebilir enerji kaynaklarını etkileyen diğer meteorolojik faktörlerin de iyi bir şekilde anlaşılmasını sağlamak açısından önemlidir.

Çalışmada kullanılan veri seti Meteoroloji Bölge Müdürlüğü Afyon Bölge İstasyonundan alınmıştır. Veri seti 26280 satır ve 8 sütundan oluşmaktadır. Tablo 1'de veri setine ait bazı parametreler

sunulmuştur. Şekil 6'da çalışmada kullanılan verilere ait grafikler verilmiştir.

Tablo 1. Veri setinin tanımlanması (Defining the dataset)

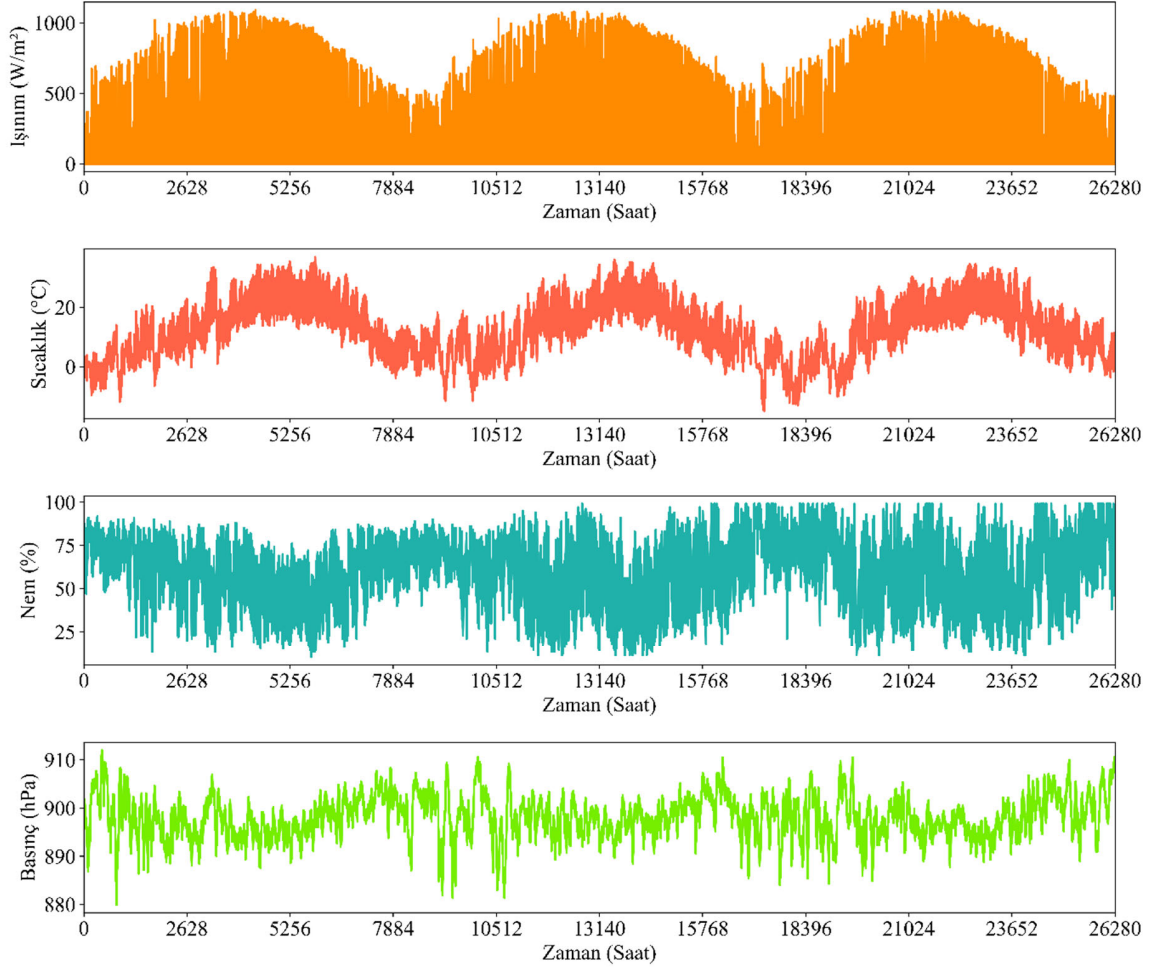
Parametre	Aralık
Yıl	2019-2021
Ay	1-12
Gün	1-31
Saat	0-23
Sıcaklık	-14.9-36.9 °C
Basınç	879.9-912 Pha
Güneş Işınımı	0-1092.2 W/m <sup>2</sup>
Nem	10-99 %

Şekil 6 incelendiğinde tüm veri değerlerinde düzenli bir değişim olmadığı gibi çeşitli nedenlerle ani dalgalanmaların meydana geldiği görülmektedir. Bu durum, özellikle bir PV çıkış gücünü büyük ölçüde etkileyen ışınım ve sıcaklık verilerini modellemenin karmaşık bir problem olduğunu göstermektedir. Bu durumun üstesinden gelmek için derin öğrenme modelleri gibi doğrusal olmayan yöntemlerin tercih edilmesi gerekmektedir. Ayrıca modelleme süresince, meteorolojik faktörler gibi çok sayıda değişkenin etkisinin dikkate alınması model başarıları için oldukça önemlidir.

#### 4.3. Veri Ön İşleme (Data Preprocessing)

Ön işleme ve özellik seçimi, derin öğrenme modellerinin başarıları için önemli bir adımdır. Ön işleme yapılan veriler daha temiz girişler oluşturduğu için derin öğrenme modellerinin daha kolay kullanılmasını sağlar. Bu sayede, modellerin doğruluğu ve sonuçları olumlu yönde etkilenir. Verilerin hazırlanması ve ön işlenmesi için aşağıdaki adımlar uygulanmıştır.

- 1- Çalışmada kullanılan giriş verilerinin bazıları dış etmenlerden dolayı ölçülemedi. Güneş ışınım şiddeti verileri hariç, tüm eksik veriler her ayın kendi ortalaması alınarak doldurulmuştur. Ancak, güneş ışınım şiddeti verileri, güneşin olmadığı (akşam) saatlerinde sıfır değerini aldığı için diğer verilerden farklıdır. Bu nedenle, güneş ışınım şiddeti verilerindeki eksikliklerin doldurulmasında ortalama almak doğru sonuçlar vermeyecektir. Bu bağlamda, eksik güneş ışınım şiddeti verileri, bulunduğu saatin bir öncesi ve bir sonrası değerlerin ortalaması alınarak tamamlanmıştır.
- 2- Bir veri seti genellikle farklı değerler arasında ölçeklendirilir. Bir derin öğrenme modeline sunulan tüm verilerin aynı ölçekte olması model başarıları için oldukça önemlidir. Veri setine tekdüzellik



Şekil 6. Saatlik meteorolojik veriler (Hourly meteorological data)

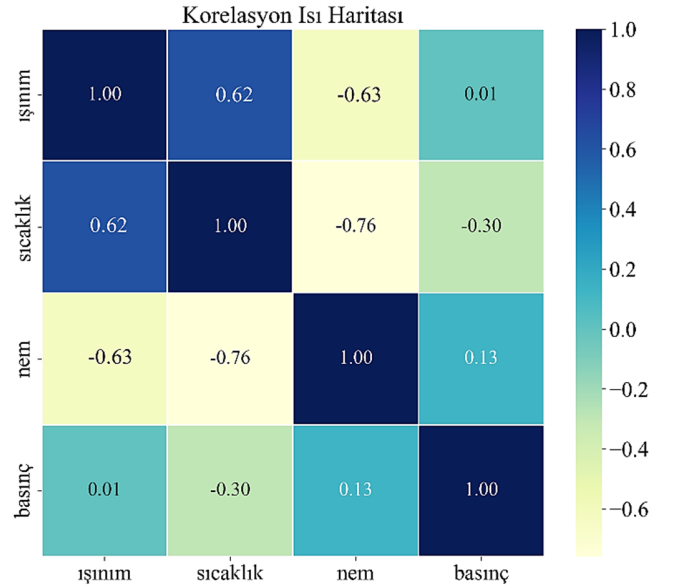
kazandırmak, verideki gürültüyü ortadan kaldırdığı gibi modelin öğrenme sürecini basitleştirir. Bu amaçla, çalışmada kullanılan veriler Min-Max yöntemi kullanılarak (0-1) arasında ölçeklendirilmiş ve Eş. 17'deki gibi hesaplanmıştır [34, 35].

$$x_{yeni} = \frac{(x - x_{min})}{x_{max} - x_{min}} \quad (17)$$

Burada,  $x_{yeni}$  normalize edilmiş veriyi,  $x$  normalize edilecek orijinal veriyi,  $x_{max}$  veri örneğinin maksimum değerini,  $x_{min}$  veri örneğinin minimum değerini göstermektedir.

#### 4.4. Özellik Seçimi (Feature Selection)

Özellik seçimi modelin doğruluğunu artıran ve öğrenme sürecini etkileyen bir faktördür. Doğru bir özellik seçimi yapıldığında model içerisinden gereksiz ve önemsiz bilgiler kaldırılabilir. Bu sayede hesaplama maliyetleri azaltılabilir, model için kritik özellikler korunabilir. Zamansal ve çeşitli meteorolojik veriler (Sıcaklık(S), Işınım Şiddeti (GIS), Nem(N), Basınç (B)) farklı derin öğrenme modelleri ve güneş ışınım şiddeti tahmini için etkili giriş parametreleri olarak kabul edilmektedir. Bu amaçla Pearson korelasyon yöntemi kullanılarak model için optimum özellikler seçilmiştir [36]. Seçilen bu özellikler ışınım şiddeti ve sıcaklık ile yüksek oranda ilişkilidir. Bu adım, başarı oranı yüksek en doğru tahmin modeli oluşturmada yardımcı olmayı amaçlamaktadır.



Şekil 7. Korelasyon matrisi (Correlation matrix)

Korelasyon katsayısı, iki değişken arasındaki doğrusal ilişkinin yönünü ve gücünü ölçen bir değerdir ve genellikle -1 ile 1 arasında bir değer alır. Bu matrisin 1 olması iki değişken arasında tam pozitif

doğrusal bir ilişki olduğunu gösterir. 0 değeri iki değişken arasında doğrusal bir ilişki olmadığını ifade eder. Bu değer -1 olması ise iki değişken arasında tam negatif doğrusal ilişki olduğunu gösterir. Şekil 7, Afyonkarahisar için korelasyon matrisini göstermektedir. Bu matrise göre, ışıınım şiddeti ve sıcaklık özellikleri için, +/- 0,6 değerinin üzerinde korelasyona sahip özellikler tahmin için etkili özellikler olarak seçilmiştir. Bu özellikler, modelin hedef değişkeni (örneğin, ışıınım şiddeti) daha doğru bir şekilde tahmin etmesine yardımcı olur. Işıınım şiddeti için sıcaklık pozitif yönde bir ilişki gösterirken, nem negatif yönde bir korelasyona sahiptir. Sıcaklık ve nem güneş ışıınım şiddeti ile en yüksek korelasyona sahipken, basınç her iki giriş (S, GIS) değeri için önemli bir korelasyon değeri göstermemiştir.

## 5. Deneysel Çalışmalar (Experimental Studies)

Makalenin bu bölümünde, M/CNN-BİLSTM\_II hibrit modelin analizi ve değerlendirilmesi için gerçekleştirilen çalışmalardan elde edilen sonuçlardan bahsedilecektir. Bu kapsamda öncelikle M/CNN-BİLSTM\_II modelinin ve diğer derin öğrenme yöntemleri için geliştirilen modellerin özellikleri Tablo 2’de verilmiştir. Giriş özellikleri, sıcaklık (S), güneş ışıınım şiddeti (GIS) ve Nem (N) olmak üzere Pearson katsayı yöntemine göre belirlenmiş olup:

a) İki giriş (S, GIS) ve iki çıkış (S, GIS), b) Üç giriş (S, GIS, N) ve iki çıkış (S, GIS), İki farklı şekilde S ve GIS ‘ın kısa dönemli tahmini için düzenlenmiştir. Tüm modeller için toplam 26280 adet verinin %70’i eğitim, %30 ‘u test verisi olarak ayrılmıştır. Her bir özellik için on saat önceki değerler girdi olarak sunulmuş ve bir saat sonrası tahmin

edilmiştir. Optimizasyon algoritması olarak Adam algoritması kullanılmış ve maliyet fonksiyonu Ortalama Karese Hata (MSE) ile hesaplanmıştır.

Tablo 2’de CNN, LSTM, GRU, SGRU, BİLSTM, CNN-LSTM, CNN-GRU, CNN-BİLSTM, CNN-SGRU modellerine ait katman özellikleri gösterilmiştir. CNN modelleri veriden anlamlı özellikler çıkarmada oldukça başarılıdır. Gün boyunca, ışıınım şiddetindeki belirli zaman dilimlerinde tekrarlayan özelliklerin yakalanmasını sağlamaktadır. LSTM modelleri zaman serisi verilerinde uzun vadeli bağımlılıkları yakalamakta etkilidir. Fakat sadece ileri yönde işlem yapar. BİLSTM modeli zaman serisi verilerini hem ileri yönde (geçmişten geleceğe) hem de geri yönde (gelecekte geçmişe) işler. Bu sayede hem geçmiş hem de gelecek bilgiyi kullanarak daha kapsamlı bir öğrenme sağlar. GRU modeli diğer modellere göre daha basit bir yapıya sahiptir. Bu özelliği ile LSTM modeline göre daha hızlı işlem yapmasını sağlar. Fakat GRU modeli karmaşık veri yapılarının tahmininde LSTM kadar başarılı olmayabilir.

Tablo 3 ve 4, CNN, LSTM, GRU, SGRU, BİLSTM, CNN-LSTM, CNN-GRU, CNN-BİLSTM ve CNN-SGRU modellerinin sıcaklık ve güneş ışıınım şiddetinin iki özelliği için değerlendirme parametrelerini göstermektedir. Daha öncede belirtildiği gibi iki farklı senaryo iki farklı giriş için uygulanmıştır. İlk senaryo, iki özellik (S, GIS), ikinci senaryo ise üç özellik (S, GIS, N) içermektedir. Modelin ilk olarak S’i daha sonra ise GIS’i tahmin etmesi beklenmektedir.

Özellik sayısının 2’den 3’e çıkarılması modellerde aşağıdaki değişikliklere neden olmuştur:

**Tablo 2.** Derin öğrenme modellerine ait yapıların özellikleri (Features of structures of deep learning models)

Model	Katman Sayısı	Filtre Boyutu	Aktivasyon Fonksiyonu	Yığın Boyutu	Eğitim Süresi	Optimizasyon Algoritması	Dropout Oranı
CNN	3	3x3	ReLU	32	50	Adam	0.2
LSTM	3	-	ReLU/tanh	32	50	Adam	0.2
GRU	3	-	ReLU/tanh	32	50	Adam	0.2
BİLSTM	3	-	ReLU/tanh	32	50	Adam	0.2
SGRU	3	-	tanh/tanh	32	50	Adam	0.2
CNN-LSTM	4	3x3	ReLU	32	50	Adam	0.2
CNN-GRU	4	3x3	ReLU	32	50	Adam	0.2
CNN-BİLSTM	4	3x3	ReLU/tanh	32	50	Adam	0.2
CNN-SGRU	4	3x3	ReLU/tanh	32	50	Adam	0.2

**Tablo 3.** Modellerin GIS tahmini değerlendirme parametreleri (GIS estimated evaluation parameters of models)

Model (Multi(M))	Girdi Özellikleri	RMSE(W/m <sup>2</sup> )	MAE(W/m <sup>2</sup> )	NRMSE (%)	R <sup>2</sup> (%)	SMAPE (%)	Eğitim Süresi (sn)
CNN_I	S, GIS	116,56	81,05	10,68	85,49	23,71	79
CNN_II	S, GIS, N	116,30	79,44	10,66	85,56	22,86	86
LSTM_I	S, GIS	80,70	44,83	7,39	93,04	16,28	167
LSTM_II	S, GIS, N	75,24	40,04	6,89	93,95	15,20	164
GRU_I	S, GIS	78,81	41,40	7,95	93,42	15,22	202
GRU_II	S, GIS, N	75,49	40,57	6,19	93,86	14,69	204
BİLSTM_I	S, GIS	77,81	41,71	7,13	93,53	19,14	212
BİLSTM_II	S, GIS, N	75,56	39,27	6,92	93,90	16,16	213
SGRU_I	S, GIS	77,21	39,50	7,05	94,02	17,36	142
SGRU_II	S, GIS, N	76,60	40,71	7	94,06	16,26	138
CNN-LSTM_I	S, GIS	76,82	38,08	7,04	93,68	16,57	123
CNN-LSTM_II	S, GIS, N	76,90	42,38	7,05	93,69	14,30	131
CNN-GRU_I	S, GIS	82,79	45,95	7,59	92,68	18,77	119
CNN-GRU_II	S, GIS, N	77,47	40,24	7,10	93,59	14,90	128
CNN-BİLSTM_I	S, GIS	73,10	39,48	6,63	93,99	15,31	302
CNN-BİLSTM_II	S, GIS, N	71,21	35,42	6,52	94,78	14,87	316
CNN-SGRU_I	S, GIS	78,23	43,67	6,98	93,59	14,53	246
CNN-SGRU_II	S, GIS, N	77,43	40,10	7,09	93,79	14,49	254

1-Tüm modellerde özellik sayısı üçe çıkarıldığında model başarısında belli bir artış görülmüştür. Bu durum nem özellik verisinin sıcaklık ve ışınım şiddeti tahmininde etkili bir faktör olduğunu göstermiştir.

2-CNN\_I modeli, ışınım şiddeti tahmininde, 116,56W/m<sup>2</sup>(RMSE), 81,05 W/m<sup>2</sup> (MAE), %10,68 (NRMSE), 23,71 (SMAPE) ve %85,49 (R<sup>2</sup>) değerleri ile diğer modellere göre daha düşük performans sergilemiştir. Sıcaklık tahmininde ise 1,81°C (RMSE),

1,39 °C (MAE), % 4,05 (NRMSE), 21,34 (SMAPE) ve %95,95 (R<sup>2</sup>) değerleri ile CNN\_I modeli düşük performans göstermiştir.

3-Her iki parametre tahmini için M/CNN-BİLSTM\_II modeli diğer modellere göre başarılı sonuçlar vermiştir.

4-Tüm modellerde model karmaşıklığı ve özellik sayısı arttıkça hesaplama süresi artış göstermiştir.

**Tablo 4.** Modellerin Sıcaklık tahmini değerlendirme parametreleri (Temperature estimation evaluation parameters of the models)

Model (Multi(M))	Girdi Özellikleri	RMSE(°C)	MAE(°C)	NRMSE (%)	R <sup>2</sup> (%)	SMAPE (%)	Eğitim Süresi (sn)
CNN_I	S, GIS	1,81	1,39	4,05	95,95	21,34	79
CNN_II	S, GIS, N	1,62	1,26	3,63	96,75	19,95	86
LSTM_I	S, GIS	0,95	0,73	2,12	98,88	14,81	167
LSTM_II	S, GIS, N	0,91	0,68	2,05	98,96	14,60	164
GRU_I	S, GIS	0,97	0,74	2,17	98,84	14,95	202
GRU_II	S, GIS, N	0,90	0,66	2,02	98,99	14,31	204
BİLSTM_I	S, GIS	0,91	0,67	2,04	98,10	13,87	212
BİLSTM_II	S, GIS, N	0,85	0,61	1,90	98,97	13,15	213
SGRU_I	S, GIS	0,97	0,73	2	99	14,11	142
SGRU_II	S, GIS, N	0,87	0,64	1,81	99,03	12,33	138
CNN-LSTM_I	S, GIS	0,93	0,69	2,10	98,91	13,09	123
CNN-LSTM_II	S, GIS, N	0,85	0,64	1,92	99,09	12,68	131
CNN-GRU_I	S, GIS	0,91	0,66	2,05	98,96	12,28	119
CNN-GRU_II	S, GIS, N	0,87	0,63	1,95	99,06	12,51	128
CNN-BİLSTM_I	S, GIS	0,78	0,59	1,64	99,21	12,66	302
CNN-BİLSTM_II	S, GIS, N	0,76	0,54	1,59	99,23	12,14	316
CNN-SGRU_I	S, GIS	0,85	0,62	1,91	99,09	13,62	246
CNN-SGRU_II	S, GIS, N	0,84	0,61	1,88	99,12	12,22	254

**Tablo 5.** M/CNN-BİLSTM modelinin basınç için GIS değerlendirme parametreleri (GIS evaluation parameters of M/CNN-BILSTM model for pressure)

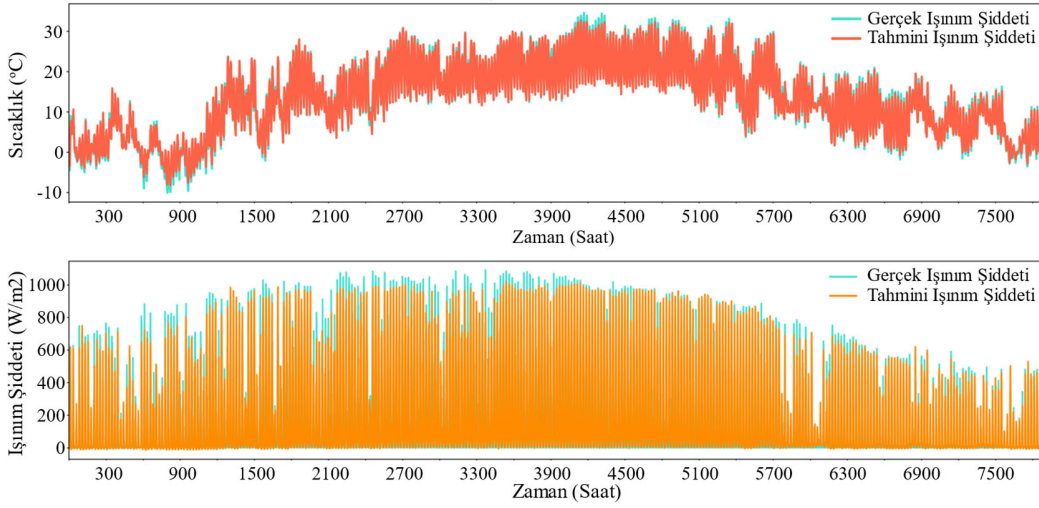
Model	Girdi Özellikleri	Değişim Miktarı	RMSE (W/m <sup>2</sup> )	MAE (W/m <sup>2</sup> )	NRMSE (%)	R <sup>2</sup> (%)	SMAPE (%)	Eğitim Süresi (sn)
M/CNN-BİLSTM_II	S, GIS, N	Değer	71,21	35,42	6,52	94,78	14,87	316
M/CNN-BİLSTM_III	S, GIS, B	Değer	76,54	40,87	7,28	93,75	15,23	317
		Değişim (%)	-7,48	-15,38	-11,65	1,08	-2,42	
M/CNN-BİLSTM_IV	S, GIS, N, B	Değer	76,55	41,33	6,98	93,54	15,30	321
		Değişim (%)	-7,49	-16,68	-11,65	1,30	-2,89	
M/CNN-BİLSTM_V	S, GIS, B, BDO	Değer	73,35	37,78	6,70	93,85	14,93	321
		Değişim (%)	-5,16	-5,56	0,14	0,80	-0,40	
M/CNN-BİLSTM_VI	S, GIS, N, B, BDO	Değer	75,67	40,02	6,72	93,62	15,06	328
		Değişim (%)	-5,61	11,81	-0,14	1,04	-1,27	

**Tablo 6.** M/CNN-BİLSTM modelinin basınç için S değerlendirme parametreleri (S evaluation parameters of the M/CNN-BILSTM model for pressure)


Model	Girdi Özellikleri	Değişim Miktarı	RMSE(°C)	MAE(°C)	NRMSE (%)	R <sup>2</sup> (%)	SMAPE (%)	Eğitim Süresi (sn)
M/CNN-BİLSTM_II	S, GIS, N	Değer	0,76	0,54	1,59	99,23	12,14	316
M/CNN-BİLSTM_III	S, GIS, B	Değer	1,36	1,05	1,83	98,13	17,93	317
		Değişim (%)	-78,94	-94,44	-15,09	1,10	-47,69	
M/CNN-BİLSTM_IV	S, GIS, N, B	Değer	1,21	0,94	1,70	98	17,88	321
		Değişim (%)	-59,21	-74,07	-6,91	1,23	-47,28	
M/CNN-BİLSTM_V	S, GIS, B, BDO	Değer	0,88	0,66	1,76	99,16	13,37	321
		Değişim (%)	-11,39	-13,79	-4,76	0,07	-10,13	
M/CNN-BİLSTM_VI	S, GIS, N, B, BDO	Değer	1,23	0,91	1,72	98,44	15,32	328
		Değişim (%)	-55,69	-56,89	-2,38	0,79	-26,19	

Çalışmada kullanılan veriler arasındaki ilişkileri açıklamak ve model başarısına etkisini araştırmak amacıyla Şekil 7'deki gibi korelasyon matrisi grafiği çıkarılmıştır. Bu grafiğe göre basınç ile sıcaklık arasında zayıf bir negatif korelasyon bulunmaktadır. Bu durum, basıncın yükseldiği durumlarda sıcaklığın hafif bir şekilde azalabileceğini, ancak bu ilişkinin çok güçlü olmadığını göstermektedir. Aynı şekilde basınç ile ışıınım arasında da güçlü bir ilişkinin olmadığı söylenebilir. Tablo 5 ve 6'da basınç (B) etkisinin sıcaklık ve ışıınım şiddeti tahminlerine etkisini görmek için, M/CNN-BiLSTM modelinde ayrı ayrı incelenmiştir. Tablolara göre basıncın sıcaklık ve ışıınım tahmininde iyileştirici bir etkisi olmadığı gibi model başarısını da düşürdüğü görülmüştür. Bu da basıncın her iki özellik için doğrudan bir etkisi olmadığını kanıtlamaktadır. Basınç değişkeninin türetilmiş bir özelliği olan basıncın bir önceki saat ile değişim oranları (BDO) hesaplanmış ve model üzerindeki etkisi gözlenmiştir. BDO modelin performansında sınırlı bir artış sağlamıştır. Basınç değişkeninin bağımsız bir girdi olarak modelde yer alması, model karmaşıklığını artırmış ve tahmin süreçlerinde ek hesaplama yükü oluşturmuştur. M/CNN-BiLSTM II ve S ve GIS için test verilerinden elde edilen tahmin grafikleri Şekil 8'de verilmiştir.

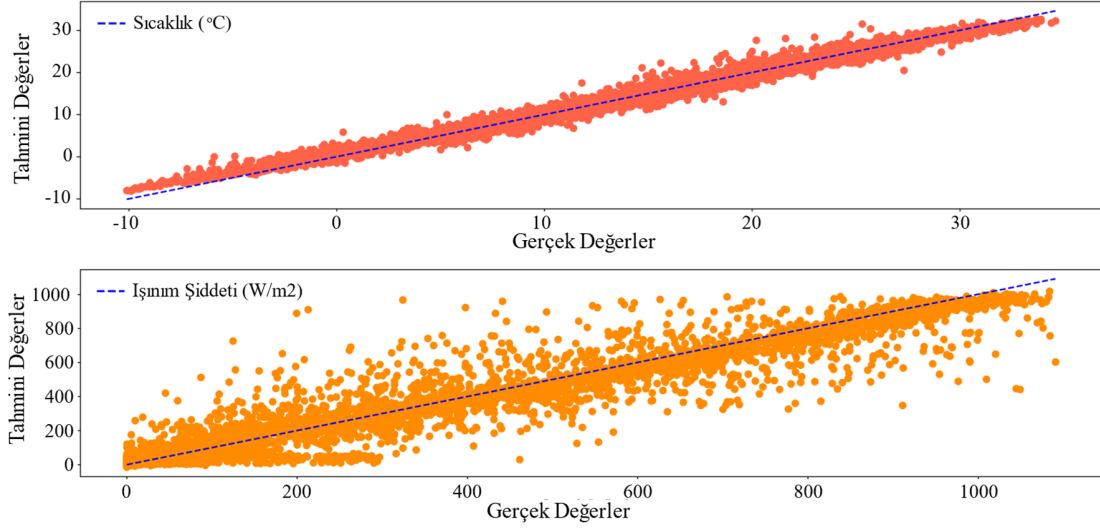
Bu model için gerçek değerler ve tahmini değerlere ait yakınlaştırılmış (5000-5200) zaman dilimine ait grafik ise Şekil 9'de verilmiştir. Modelin verimliliğini incelemenin bir diğer yolu ise gerçek ve tahmin edilen değerler arasındaki regresyon eğrisidir. Tahmin edilen noktaların,  $x=y$  doğrusuna olan yakınlığı, gerçek değer ile tahmin edilen değer arasındaki uyumu göstermektedir. Şekil 10'da sıcaklık ve GIS regresyon eğrileri verilmiştir. Buna göre sıcaklık ve GIS gerçek ve tahmin verileri arasında anlamlı bir korelasyon olduğu görülmektedir. ışıınım ve sıcaklık ile ilgili hata grafikleri, tahmin modelinin performansını ve tahminlerinin ne kadar doğru olduğunu anlamak için kullanılan önemli araçlardır. Hata grafikleri, genellikle tahmin edilen değer ile gerçek değer arasındaki farkı (hata) zamana göre gösterir. Şekil 11'de sıcaklık ve ışıınım şiddetine ait hata grafikleri verilmiştir. Grafikler incelendiğinde her iki tahmin için modelin genel olarak sıfıra yakın hata değerleri ürettiği görülmektedir. Ancak ışıınım şiddeti tahmininde sıcaklığa göre daha geniş sapmalar meydana gelmektedir. Bu durum, ışıınım şiddetinin günün belirli saatlerinde veya belirli hava koşullarında ani değişimlerinden kaynaklandığı ve ışıınım şiddeti tahminlerinin daha zorlu bir görev olduğunu göstermektedir.



Şekil 8. CNN-BiLSTM\_II ait sıcaklık ve güneş ışıınım şiddetine ait gerçek ve tahmin grafikleri (Actual and estimated graphs of temperature and solar radiation intensity of CNN-BiLSTM\_II)




Şekil 9. Sıcaklık ve güneş ışıınım şiddetine ait yakınlaştırılmış (5000-5200) gerçek ve tahmin grafikleri (Zoomed (5000-5200) actual and predicted graphs of temperature and solar Radiation)



**Şekil 10.** M/CNN-BİLSTM\_II modelinin sıcaklık ve GIS verilerinin tahmin edilen ve gerçek değerlerinin test verileri üzerindeki regresyon grafiği

(Regression plot of predicted and actual values of temperature and GIS data of M/CNN-BILSTM II model on test data)



**Şekil 11.** M/CNN-BİLSTM\_II modeli için sıcaklık ve ışınım şiddeti hata grafikleri  
(Temperature and solar radiation error graphs for the M/CNN-BILSTM\_II model)


Çalışmada kullanılan modeller arasında, Model\_II grubu, Model\_I grubuna kıyasla daha iyi performans göstermiştir. Model\_II grubuna ait sıcaklık ve ışınım değerleri için oluşturulan regresyon grafikleri, sırasıyla Şekil 12 ve Şekil 13'de sunulmaktadır.

Tablo 7'de CNN-BİLSTM\_II modeli ile literatürdeki benzer çalışmalar kıyaslanmıştır. Tablo 7 için ilk satırda önerilen model olan CNN-BİLSTM\_II modelinden elde edilen sonuçlar verilmiştir. Band vd. [37], güneş radyasyonu tahmini için Çok değişkenli varyasyonel mod ayrıştırma-LSTM hibrit modelini kullanmışlardır. Hibrit modelin başarılı sonuçlar verdiği görülmüştür. Şener vd. yaptığı bir çalışmada Muş ili için hibrit optimize edilmiş CNN-LSTM modelini geliştirmiştir [38]. Eşlik ve meslektaşları, Afyon ili (2024) için güneş radyasyonunu tahmin etmek amacıyla hibrit derin öğrenme modeli kullanmışlardır [39]. Önerilen yöntemin daha önce yayınlanmış çalışmalar arasında iyi bir konumda olduğu görülmektedir.

## 6. Sonuçlar ve Tartışmalar (Results and Discussions)

Çalışmada, çeşitli derin öğrenme modelleri iki farklı senaryo ile oluşturulmuştur. Birinci senaryoda girdi olarak iki özellik (S ve GIS) dikkate alınırken, ikinci senaryoda Pearson katsayısı kullanılarak üç özellik (S, GIS ve N) modellere girdi olarak sunulmuştur. Üç girdili senaryo tüm modellerde, iki girdili senaryoya göre başarılı sonuçlar vermiştir. Bu da her iki parametrenin tahmininde, nem değişkeninin tahmin başarısını iyileştirdiği sonucu göstermektedir.

Ayrıca çalışmada, derin öğrenme modelleri ve hibrit kombinasyonları arasında hem sıcaklık hem de ışınım şiddeti tahmininde en başarılı sonuç M/CNN-BİLSTM\_II modelinden elde edilmiştir. Işınım şiddeti tahmininde, RMSE, MAE, NRMSE, SMAPE ve  $R^2$  metrikleri kullanılmış ve sırası ile 71,21 W/m<sup>2</sup>, 35,42 W/m<sup>2</sup>, %6,52, %14,87 ve %94,78 hesaplanmıştır. Sıcaklık tahmin sonuçları ise RMSE, MAE,



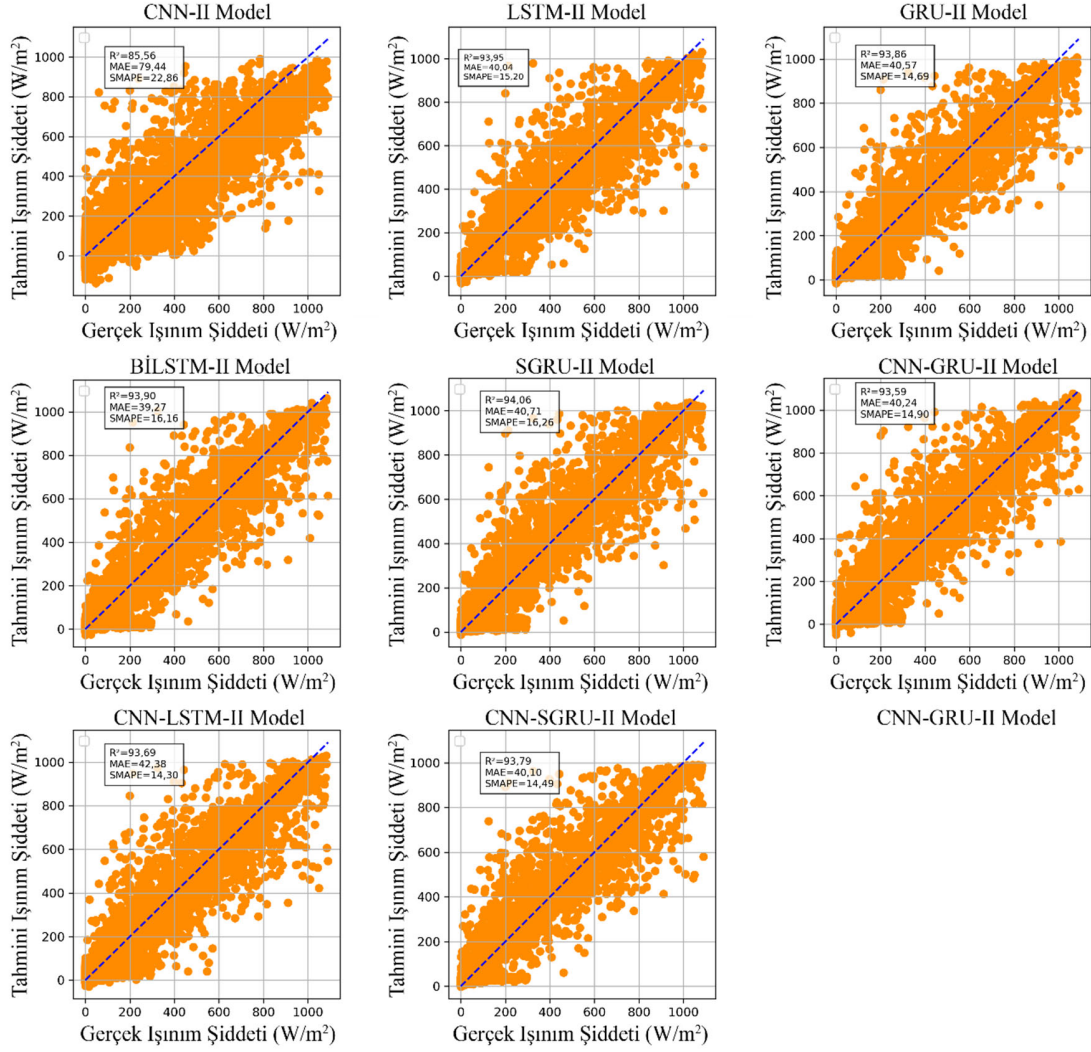
**Şekil 12.** Model\_II grubu için sıcaklık değerlerinin karşılaştırmalı regresyon grafikleri  
(Comparative regression graphs of temperature values for Model\_II group)

NRMSE ve  $R^2$  metrikleri için sırasıyla  $0,76^{\circ}\text{C}$ ,  $0,54^{\circ}\text{C}$ , %1,59, %12,14 ve %99,23 olarak hesaplanmıştır. Sonuçlar incelendiğinde, aynı modeller için sıcaklık tahmini, ışınım şiddeti, tahmininden daha başarılı sonuçlar sergilemiştir. Sıcaklık verisi gün içinde yavaş değişen, gündüz ve gece arasında daha az dalgalanma gösteren bir veri yapısına sahiptir. Halbuki güneş ışınım şiddeti verileri, hava durumu, günün saati gibi faktörlere bağlı olarak fazla dalgalanma ve ani değişimler sergilemektedir. Güneş ışınım şiddetindeki bu ani değişimler bir bulutun hareketi, sis, hava kirliliği, yağış, gölgelenme gibi sebeplerden meydana gelebilir. Bu da tahmin modelleri için zorluk yaratır ve model başarısını etkiler. Model başarısını artırmak için veri içerisindeki eksik veriler o verinin yapısına uygun bir şekilde doldurulmalıdır.

Çalışmada, basınç değişkeninin, M/CNN-BİLSTM\_II modelinin başarısı üzerindeki etkilerini incelemek için iki farklı girdi durumunda sıcaklık ve GIS tahmini yapılmıştır. Birinci durumda M/CNN-BİLSTM\_III modeline S, GIS ve B girdi olarak sunulmuştur. M/CNN-BİLSTM\_III modeli, M/CNN-BİLSTM\_II modeli ile kıyaslandığında sıcaklık tahmininde hata değerleri RMSE, MAE, NRMSE ve SMAPE için sırası ile %78,94, %94,44, %15,09 ve %47,69 artmıştır.  $R^2$  değeri ise %1,10 oranında azalmıştır. Işınım şiddeti tahmininde ise RMSE değeri %7,48, MAE %15,38, NRMSE %11,65 ve SMAPE %2,42 oranında artarken,  $R^2$  değeri %1,08 oranında azalmıştır. İkinci durumda CNN-BİLSTM\_IV modeline S,

GIS, N ve B girdi olarak sunulmuştur. Sıcaklık tahmininde, RMSE değeri %59,21, MAE değeri %74,07, NRMSE %6,91 ve SMAPE %47,28 oranında artarken,  $R^2$  değeri %1,23 oranında azalmış ve ışınım şiddeti tahmininde ise RMSE değeri %7,49, MAE değeri %16,68, NRMSE değeri 11,65 ve SMAPE değeri 2,89 oranında artarken,  $R^2$  değeri %1,30 oranında azalma göstermiştir. M/CNN-BİLSTM\_V ve M/CNN-BİLSTM\_VI modelleri ise basınç değişkeninin farklı kombinasyonlardaki değişimini görmek için tasarlanmıştır. Basıncın bir önceki saatle değişim oranları (BDO) hesaplanarak modele eklenmiş, ancak performansta sınırlı bir artış sağlanmıştır. Basınç değişkeninin bağımsız girdi olarak eklenmesi, model karmaşıklığını artırmış ve ek hesaplama yükü oluşturmuştur.

Tablo 3 ve 4'te, modellerin iş yükünü değerlendirmek amacıyla eğitim süreleri hesaplanmıştır. Beklendiği üzere, hibrit modellerin daha karmaşık yapıları, hesaplama maliyetlerini artırmıştır. Bu durum, hibrit modellerin hesaplama süresi açısından daha yüksek bir yük oluşturduğunu göstermektedir. Algoritmalar, 8 GB RAM'e sahip Intel® Core i7-9750H (2.6GHz) işlemci üzerinde çalışan, Windows 10 işletim sistemine sahip bir bilgisayarda çalıştırılmıştır. Şekil 12 ve 13'te elde edilen regresyon eğrilerine ait grafikler incelendiğinde ise CNN tabanlı modeller ile GRU ve LSTM kombinasyonlarının, sıradan CNN veya LSTM tabanlı modellere kıyasla sıcaklık ve ışınım tahmini görevinde daha üstün bir performans sergilediği gözlemlenmiştir.



**Şekil 13.** Model\_II grubu için ışıınım şiddeti değerlerinin karşılaştırılmalı regresyon grafikleri  
(Comparative regression graphs of solar radiation values for Model\_II group)

**Tablo 7.** Önerilen modelin ve diğer mevcut modellerin performanslarının karşılaştırılması  
(Comparison of the performances of the proposed model and other current models)

Literatür	Metot	Veri	R <sup>2</sup> (%)	Bölge
Önerilen Model	CNN-BiLSTM_II	Güneş ışıınım şiddeti/Sıcaklık	94,78/99,23	Afyon-Türkiye
Band vd. [37]	Çok değişkenli varyasyonel mod ayrıştırma-LSTM	Güneş ışıınım şiddeti	92,4	Illinois-ABD
Şener vd. [38]	Hibrit optimize edilmiş CNN-LSTM	Güneş ışıınım şiddeti	74,94	Muş-Türkiye
Eşlik vd. [39]	CNN-LSTM	Güneş ışıınım şiddeti	70,668	Afyon-Türkiye

### Sonuçlar (Conclusions)

Bu çalışmanın amacı, bir bölgeye kurulması planlanan güneş enerji santrali için çok değişkenli meteorolojik girdilerin, iki değişkenli çıktılara etkisini inceleyip kısa dönem tahmin yaparak, doğru, ekonomik ve çevresel analizler yapılmasına katkı sağlamaktır. Geleceğin en önemli enerji kaynaklarından biri olarak kabul edilen yenilenebilir elektrik enerjisine yapılan yatırımlar, ülkelerin dışa bağımlılığını azaltmakta, endüstriyel ve teknolojik ilerlemeyi teşvik

etmekte, istihdamı artırmakta ve aynı zamanda ekonomik büyümeye önemli bir destek sağlamaktadır. Çalışmadan elde edilen sonuçların, bir bölgeye kurulması planlanan güneş enerji santrallerinin doğru, ekonomik ve çevresel analizlerinin yapılmasına ve enerji sektöründeki yatırımların artmasına önemli katkılar sağlayacağı düşünülmektedir. Ayrıca, doğru tahmin modelleri enerji piyasasında arz-talep dengesinin sağlanmasında güvenilir bir rol oynamaktadır. M/CNN-BiLSTM\_II modelinin başarısı, güneş enerjisi sistemlerindeki dalgalanmalara karşı erken uyarı sistemlerinin

geliştirilmesi açısından önemlidir. Çalışmada kullanılan veriler Afyonkarahisar ile sınırlı olmakla birlikte, analiz edilen meteorolojik büyüklüklerin güneş ışınımıyla ilişkisi evrensel fiziksel süreçlere dayanmaktadır. Bu nedenle, geliştirilen modellerin yapısal prensipleri diğer bölgelerde de geçerliliğini koruyabilir. Farklı coğrafi bölgelerdeki veri yoğunluğu, bulutluluk yapısı, coğrafi farklılıklar ve bölgesel atmosferik özellikler modelin tahmin başarısını etkileyebilecek önemli etkenlerdir. Bu amaçla, gelecek çalışmalarda geliştirilen modelin farklı iklim koşullarına sahip bölgelerde uygulanarak performansının değerlendirilmesi ve Transformer tabanlı modellerin entegrasyonu planlanmaktadır.

#### Teşekkür (Acknowledgement)

Bu çalışmada kullanılan meteorolojik verilerin temininde gösterdikleri destekten dolayı Afyonkarahisar Meteoroloji Bölge Müdürlüğü'ne teşekkür ederiz.

#### Kaynaklar (References)

1. Wang, Y., Fu, W., Wang, J., Zhen, Z., & Wang, F., Ultra-short-term distributed PV power forecasting for virtual power plant considering data-scarce scenarios, *Applied Energy*, 373, 123890, 2024.
2. Energy Institute. Statistical Review of World Energy. <https://www.energyinst.org/statistical-review>, Yayın tarihi Şubat 2022. Erişim tarihi Temmuz 23, 2024.
3. Neshat, M., Nezhad, M. M., Mirjalili, S., Garcia, D. A., Dahlquist, E., & Gandomi, A. H., Short-term solar radiation forecasting using hybrid deep residual learning and gated LSTM recurrent network with differential covariance matrix adaptation evolution strategy, *Energy*, 278, 127701, 2023.
4. Sonkavde, G., Dharrao, D. S., Bongale, A. M., Deokate, S. T., Doreswamy, D., & Bhat, S. K., Forecasting stock market prices using machine learning and deep learning models: A systematic review, performance analysis and discussion of implications, *International Journal of Financial Studies*, 11 (3), 94, 2023.
5. Guijo-Rubio, D., Durán-Rosal, A. M., Gutiérrez, P. A., Gómez-Orellana, A. M., Casanova-Mateo, C., Sanz-Justo, J., & Hervás-Martínez, C., Evolutionary artificial neural networks for accurate solar radiation prediction, *Energy*, 210, 118374, 2020.
6. Bhardwaj, S., Sharma, V., Srivastava, S., Sastry, O. S., Bandyopadhyay, B., Chandel, S. S., Gupta, J. R. P., Estimation of solar radiation using a combination of Hidden Markov Model and generalized Fuzzy model, *Solar energy*, 93, 43-54, 2013.
7. Sharadga, H., Hajimirza, S., & Balog, R. S., Time series forecasting of solar power generation for large-scale photovoltaic plants, *Renewable Energy*, 150, 797-807, 2020.
8. Ertürk, S., Kara, H., Akkuş, C., & Genç, G., Türkiye'de Farklı İklim Kuşakları İçin Yapay Sinir Ağları Kullanılarak Güneş Işınımının Tahmini, *Gazi University Journal of Science Part C: Design and Technology*, 11 (4), 885-892, 2023.
9. Arslan, G., Bayhan, B., & Yaman, K., Mersin/Türkiye için Ölçülen Global Güneş Işınımının Yapay Sinir Ağları ile Tahmin Edilmesi ve Yaygın Işınım Modelleri ile Karşılaştırılması, *Gazi University Journal of Science Part C: Design and Technology*, 7 (1), 80-96, 2019.
10. Elsaraiti, M., & Merabet, A., Solar power forecasting using deep learning techniques, *IEEE access*, 10, 31692-31698, 2022.
11. Gupta, R., Yadav, A. K., & Jha, S. K., Harnessing the power of hybrid deep learning algorithm for the estimation of global horizontal irradiance, *Science of The Total Environment*, 173958, 2024.
12. Michael, N. E., Bansal, R. C., Ismail, A. A. A., Elnady, A., & Hasan, S., A cohesive structure of Bi-directional long-short-term memory (BiLSTM)-GRU for predicting hourly solar radiation, *Renewable Energy*, 222, 119943, 2024.
13. Bakht, M. P., Mohd, M. N. H., Ibrahim, B. S. K. K., Khan, N., Sheikh, U. U., & Ab Rahman, A. A. H., Advanced Automated Machine Learning Framework for Photovoltaic Power Output Prediction Using Environmental Parameters and SHAP Interpretability, *Results in Engineering*, 103838, 2025.
14. Mohanty, P., Subhadarshini, K., Nayak, R., Pati, U. C., & Mahapatra, K., Exploring data-driven multivariate statistical models for the prediction of solar energy, In *Computer Vision and Machine Intelligence for Renewable Energy Systems*, Elsevier, 85-101, 2025.
15. Agga, A., Abbou, A., Labbadi, M., & El Houm, Y., Short-term self consumption PV plant power production forecasts based on hybrid CNN-LSTM, ConvLSTM models, *Renewable Energy*, 177, 101-112, 2021.
16. Xie, X., Xu, W., & Tan, H., The day-ahead electricity price forecasting based on stacked CNN and LSTM. In *Intelligence Science and Big Data Engineering: 8th International Conference, IScIDE 2018, Lanzhou, China, August, 18-19, 2018, Revised Selected Papers 8 Springer International Publishing*, 216-230, 2018.
17. Michael, N. E., Bansal, R. C., Ismail, A. A. A., Elnady, A., & Hasan, S., A cohesive structure of Bi-directional long-short-term memory (BiLSTM)-GRU for predicting hourly solar radiation, *Renewable Energy*, 222, 119943, 2024.
18. Chadha, G. S., Schwung, A., Learning the non-linearity in convolutional neural networks, *arXiv preprint arXiv:1905.12337*, 2019.
19. Sabri, M., & El Hassouni, M., Predicting photovoltaic power generation using double-layer bidirectional long short-term memory-convolutional network, *International Journal of Energy and Environmental Engineering*, 14 (3), 497-510, 2023.
20. Zhu, H., Zhang, X., Wu, J., Hu, S., & Wang, Y. A novel solar irradiance calculation method for distributed photovoltaic power plants based on K-dimension tree and combined CNN-LSTM method, *Computers and Electrical Engineering*, 122, 109990, 2025.
21. Wojtkiewicz, J., Hosseini, M., Gottumukkala, R., & Chambers, T. L., Hour-ahead solar irradiance forecasting using multivariate gated recurrent units, *Energies*, 12 (21), 4055, 2019.
22. Su, Z., Gu, S., Wang, J., & Lund, P. D., Improving ultra-short-term photovoltaic power forecasting using advanced deep-learning approach, *Measurement*, 239, 115405, 2025.
23. Zhou, H., Chen, W., Liu, J., Cheng, L., & Xia, M., Trustworthy and intelligent fault diagnosis with effective denoising and evidential stacked GRU neural network, *Journal of Intelligent Manufacturing*, 1-20, 2023.
24. Zhang, Y. M., & Wang, H., Multi-head attention-based probabilistic CNN-BiLSTM for day-ahead wind speed Forecasting, *Energy*, 278, 127865, 2023.
25. Bashir, T., Wang, H., Tahir, M., & Zhang, Y., Wind and solar power forecasting based on hybrid CNN-ABiLSTM, CNN-transformer-MLP models, *Renewable Energy*, 239, 122055, 2025.
26. Azizi, N., Yaghoobirad, M., Farajollahi, M., & Ahmadi, A., Deep learning based long-term global solar irradiance and temperature forecasting using time series with multi-step multivariate output, *Renewable Energy*, 206, 135-147, 2023.
27. Guher, A. B., & Tasdemir, S., Determining of solar power by using machine learning methods in a specified region, *Tehnički vjesnik*, 28 (5), 1471-1479, 2021.
28. Akkurt N., Hasgöl, S., Comparison of automated machine learning (AutoML) libraries in time series forecasting, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39 (3), 1693-1702, 2024.
29. Chen, Y., Lin, C., Liu, J., & Yu, D., One-hour-ahead solar irradiance forecast based on real-time K-means++ clustering on the input side and CNN-LSTM, *Journal of Atmospheric and Solar-Terrestrial Physics*, 106405, 2024.
30. Guher, A. B., Tasdemir, S., & Yaniktepe, B., Effective estimation of hourly global solar radiation using machine learning algorithms, *International Journal of Photoenergy*, 2020 (1), 8843620, 2020.
31. Bae, G., Real-Time DNI and DHI Prediction Using Weather Information via LGBM. In *Science and Information Conference (pp. 481-489)*, Cham: Springer Nature Switzerland, 2023.
32. Türkiye Meteoroloji Genel Müdürlüğü. <https://mgm.gov.tr/veridegerlendirme>. Erişim tarihi Temmuz 23, 2024.
33. Enerji ve Tabii Kaynaklar Bakanlığı. <https://gepa.enerji.gov.tr/>. Erişim tarihi Temmuz 23, 2024.
34. Kaysal, A., Köroğlu, S., & Oğuz, Y., Hierarchical energy management system with multiple operation modes for hybrid DC microgrid, *International Journal of Electrical Power & Energy Systems*, 141, 108149, 2022.
35. Jaihuni, M., Basak, J. K., Khan, F., Okyere, F. G., Sihalath, T., Bhujel, A., Kim, H. T., A novel recurrent neural network approach in forecasting short term solar irradiance, *ISA transactions*, 121, 63-74, 2022.

36. Ghimire, S., Nguyen-Huy, T., Deo, R. C., Casillas-Perez, D., Salcedo-Sanz, S., Efficient daily solar radiation prediction with deep learning 4-phase convolutional neural network, dual stage stacked regression and support vector machine CNN-REGST hybrid model, Sustainable Materials and Technologies, 32, e00429, 2022.
37. Band, S. S., Qasem, S. N., Ameri, R., Pai, H. T., Gupta, B. B., Mehdizadeh, S., & Mosavi, A., Deep learning hybrid models with multivariate variational mode decomposition for estimating daily solar Radiation, Alexandria Engineering Journal, 105, 613-625, 2024.
38. Şener, İ. F., & Tuğal, İ. Optimized CNN-LSTM with Hybrid Metaheuristic Approaches for Solar Radiation Forecasting, Case Studies in Thermal Engineering, 106356, 2025.
39. Eşlik A.H., Sen O., Serttaş F., CNN-LSTM model for solar radiation prediction: performance analysis, Journal of the Faculty of Engineering and Architecture of Gazi University, 39 (4), 2155-2162, 2024.