



CNN-LSTM model for solar radiation prediction: performance analysis

Ardan Hüseyin Eşlik^{1*}, Ozan Şen², Fatih Serttaş¹

¹Department of Electric Engineering, Faculty of Engineering, Afyon Kocatepe University, 03204, Afyonkarahisar, Türkiye

²Department of Mechanical Engineering, Faculty of Technology, Afyon Kocatepe University, 03204, Afyonkarahisar, Türkiye

Highlights:

- A novel hybrid deep learning model (CNN+LSTM) for solar radiation prediction is proposed.
- Solar radiation data measured by a pyranometer in Afyonkarahisar province are used.
- Comparisons with other machine learning methods have demonstrated the feasibility of the model.

Keywords:

- Solar Radiation Prediction
- Deep Learning
- Time Series Prediction
- Long-Short-Term Memory
- Machine learning

Article Info:

Research Article

Received: 28.01.2023

Accepted: 26.11.2023

DOI:

10.17341/gazimmfd.1243823

Correspondence:

Author: Ardan Hüseyin Eşlik
e-mail: ardanhuseyineslik@gmail.com
phone: +90 272 218 2487

Graphical/Tabular Abstract

This study proposes a deep hybrid neural network method to improve the daily mean solar irradiance estimation by effectively capturing complex and nonlinear patterns in time series data. In this hybrid architecture, convolution layers in the CNN architecture extract valuable features from the input data. Then the extracted useful features are given as input to the LSTM layers. Using LSTM layers, sequential data can be processed, and long-term information can be learned. Finally, the output from the LSTM layers is given to the Fully Connected Layer, and radiation estimates are reached. The flow chart of the proposed hybrid deep learning model (CNN+LSTM) can be seen in Figure A. Comparative experiments revealed that the hybrid deep learning model has encouraging results.

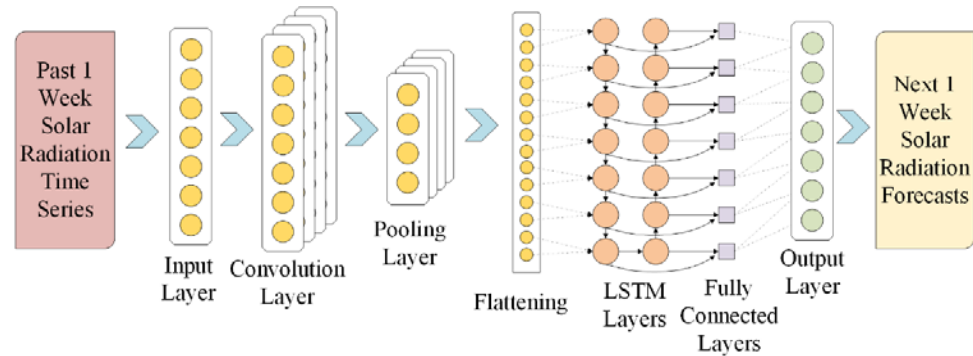


Figure A. Proposed Hybrid Deep Learning Model (CNN+LSTM) Flow Chart

Purpose:

Due to the need for clean and sustainable energy worldwide, the interest in solar energy production is increasing daily. This study aims to create an efficient forecasting model by using a combination of CNN and LSTM techniques. The aim is to show that the proposed deep learning-based model outperforms traditional machine learning models.

Theory and Methods:

Modeling solar radiation data with high variability is a complex problem, and nonlinear methods are needed. In this context, a hybrid model consisting of Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM) networks is proposed for solar radiation prediction. The study used measured solar radiation values from a pyranometer located on the Afyon Kocatepe University campus. The performance and applicability of the proposed model are examined by comparing it with different machine learning methods such as Decision Tree Regression, Random Forest Regression, and K-Nearest Neighbor.

Results:

The prediction performance of the proposed hybrid model is compared with other machine learning methods using four different statistical evaluation criteria (MAE, RMSE, MAPE, and r^2). The results revealed that the proposed hybrid model is the most successful prediction model by all statistical evaluation criteria compared to other benchmarking models.

Conclusion:

In this study, a hybrid deep learning model consisting of CNN and LSTM networks is proposed to predict mean solar radiation during the day, and the performance and applicability of the method are investigated. The results revealed that the proposed CNN+LSTM hybrid deep learning model gives better results than machine learning algorithms in all RMSE, MAE, MAPE, and r^2 statistical evaluation criteria and can be used effectively in predicting daily average solar radiation.



Güneş ışıını tahmini için CNN-LSTM modeli: performans analizi

Ardan Hüseyin Eşlik^{1*}, Ozan Şen², Fatih Serttaş¹

¹Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, 03204, Afyonkarahisar, Türkiye

²Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Makine Mühendisliği Bölümü, 03204, Afyonkarahisar, Türkiye

Ö N E Ç I K A N L A R

- Güneş ışıını tahmini için CNN ve LSTM ağlarından oluşan özgün ve hibrit bir derin öğrenme modeli
- Afyonkarahisar'da ölçümü gerçekleştirilen ışıını verileri kullanılarak dört farklı model ile performans karşılaştırması
- Diğer modellere oranla yüksek güneş ışıını tahmin performansı

Makale Bilgileri

Araştırma Makalesi

Geliş: 28.01.2023

Kabul: 26.11.2023

DOI:

10.17341/gazimmfd.1243823

Anahtar Kelimeler:

Güneş ışıını tahmini,
derin öğrenme,
uzun-kısa süreli bellek,
zaman serisi tahmini,
makine öğrenmesi

ÖZ

Güneş enerjisinin potansiyelinden tam anlamıyla faydalanmak ve güneş enerjisi sistemlerini etkin bir şekilde işletilebilmek için güneş ışıını değerinin bilinmesi büyük önem arz etmektedir. Yüksek değişkenliğe sahip güneş radyasyonu verilerinin modellenmesi karmaşık bir problemdir ve doğrusal olmayan yöntemlere ihtiyaç vardır. Bu çalışmada, güneş ışıını tahmini için CNN ve LSTM mimarileri kullanılarak oluşturulan hibrit bir model önerilmiştir. Önerilen modelin performansı ve uygulanabilirliği ARIMA istatistiksel yöntemi ve Rastgele Orman, Karar Ağaçları, K-En Yakın Komşu gibi farklı makine öğrenmesi yöntemleri ile karşılaştırılarak incelenmiştir. Çalışmada, Afyon Kocatepe Üniversitesi yerleşkesine konumlandırılan bir piranometre ile saatlik olarak ölçülmüş güneş ışıını değerleri kullanılmıştır. Deneysel çalışmalar sonucunda CNN-LSTM modeli RMSE, MAE, MAPE ve r^2 değerlendirme kriterleri açısından en başarısız tahminleri üreten Karar Ağaçları modeline oranla sırasıyla %16,92, %17,25, %17,24, %22,89 daha başarılı sonuçlar elde ederek en başarılı tahminleri gerçekleştiren model olmuştur.

CNN-LSTM model for solar radiation prediction: performance analysis

H I G H L I G H T S

- A novel hybrid deep learning model for solar irradiance prediction using CNN and LSTM networks
- Performance comparison with four different models using radiation data measured in Afyonkarahisar
- High solar radiation estimation performance compared to other models

Article Info

Research Article

Received: 28.01.2023

Accepted: 26.11.2023

DOI:

10.17341/gazimmfd.1243823

Keywords:

Solar radiation prediction,
deep learning,
long-short-term memory,
time series prediction,
machine learning

ABSTRACT

To fully utilize the potential of solar energy and effectively operate solar energy systems, it is vital to know solar radiation values. Modeling solar radiation data with high variability is a complex problem, and nonlinear methods are needed. This study proposes a hybrid model using CNN and LSTM architectures for solar radiation prediction. The performance and applicability of the proposed model are examined by comparing it with ARIMA statistical method and different machine learning methods such as Random Forest, Decision Tree and K-Nearest Neighbor. The study used hourly solar radiation values measured with a pyranometer on the Afyon Kocatepe University campus. As a result of the experimental studies, the CNN-LSTM model is the most successful model in terms of RMSE, MAE, MAPE and r^2 evaluation criteria, achieving 16.92%, 17.25%, 17.24%, 22.89% more successful results than the Decision Trees model, which produced the most unsuccessful predictions, respectively.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *ardanhuseyineslik@gmail.com, oozansenn@gmail.com, serttasf@gmail.com /
Tel: +90 272 218 2487

1. Giriş (Introduction)

Dünyada hızla artan enerji ihtiyaçları nedeniyle fosil yakıtlara alternatif, temiz ve sürdürülebilir nitelikte olan yenilenebilir enerji kaynaklarına yönelim hız kazanmıştır. Yenilenebilir enerji kaynaklarından güneş enerjisi, 2021 yılında kurulu en iyi elektrik üretim kaynağı olarak belirlenmiştir. Bununla birlikte, yeni eklenen 300 GW'ı geçkin yenilenebilir enerji üretim kapasitesinde, 167,8 GW şebekeye bağlı kapasite değeri ile %56'lık bir payın sahibi olmuştur. Tüm bu şartlar ve dünyadaki enerji üretim kapasiteleri dikkate alındığında bu istikrarlı artış eğiliminin devam etmesi beklenmektedir [1].

Fotovoltaik panellerdeki güç çıkışı değeri büyük oranda güneş ışınımına bağlı olarak değişmektedir. Gün içi ışınım değerinde sıklıkla yaşanabilen ani artma ve azalmalar panellerden elde edilen çıkış güçlerinde büyük değişkenliklere neden olmaktadır. Bu değişkenlikler ile birlikte yerel güç kalitesi ve kararlılık sorunlarına ek olarak voltaj dalgalanmaları yaşanabilmektedir. Ayrıca kurulması planlanan elektrik şebekesinin entegrasyon maliyetlerini arttırmaktadır [2]. Güneş enerjisinde yaşanan bu kesintili ve değişken üretim ile başa çıkabilmek için depolama, dağıtılmış güneş enerjisi üretimi gibi farklı çözümler geliştirilmiştir. Ancak bu çözümler de farklı maliyetleri beraberinde getirmektedir. Dolayısıyla güneş enerjisinden en efektif şekilde yararlanma arayışı oluşmuş ve sonucunda enerji yönetim sistemleri ortaya çıkmıştır. Enerji yönetim sistemleri yüksek güç kalitesi sağlarken enerji maliyetlerini en aza indirmek için kullanıcının enerji tüketimini, dağıtılmış üretimi ve depolamasını planlamakta ve koordine etmektedir. Enerji yönetim sistemlerinin doğru stratejileri geliştirebilme ve planlamaları yapabilmesi ise panellerin güç çıkışlarında ve elektrik taleplerindeki değişiklikleri büyük oranda öngörebilmesi ile mümkün olmaktadır. Bu nedenle, güneş ışınımının ve dolayısıyla fotovoltaik panellerin güç üretiminin doğru tahmini, panellerin üretiminin belirsizlik etkisinin azaltılmasında, pil depolama şarj kontrolörlerinin kontrol algoritmalarının iyileştirilmesinde ve depolama sistemlerine ekonomik fayda sağlanmasında büyük rol oynamaktadır [3].

Gerçekleştirilen çalışmada, derin öğrenme yöntemlerinden evrişimli sinir ağları ve uzun-kısa süreli bellekten oluşan hibrit bir model kullanılarak güneş ışınımı tahminleri gerçekleştirilmiş ve ilgili yaklaşımın performansı ve uygulanabilirliği incelenmiştir. Çalışmamızda, Afyon Kocatepe Üniversitesi yerleşkesinde yer alan Güneş ve Rüzgâr Uygulama ve Araştırma Merkezi'ne (GÜRAM) konumlandırılmış bir piranometre aracılığıyla saatlik olarak toplanmış olan ışınım verileri kullanılmıştır. 2012 yılı içerisinde toplanmış olan veriler modelin eğitiminde, 2013 yılı içerisinde toplanmış olan veriler ise modelin testinde kullanılmıştır. Oluşturulan modelin sonuçları farklı makine öğrenmesi ve istatistiksel yöntemlerle karşılaştırılarak performansı ve etkinliği değerlendirilmiştir.

Makalenin organizasyonu şu şekilde planlanmıştır: Bölüm 2'de literatürde gerçekleştirilen benzer çalışmalar, Bölüm 3 metodoloji başlığı altında zaman serisi tahmini, derin öğrenme, kullanılan veri, evrişimli sinir ağları ve uzun-kısa süreli bellek ağları açıklanmıştır. Bölüm 4'de verinin hazırlanma süreci, değerlendirme kriterleri ve gerçekleştirilen deneysel çalışmalardan bahsedilmiştir. Bölüm 5'de ise deneysel çalışmalara ait analiz sonuçlarına yer verilmiştir.

2. İlgili Çalışmalar (Related Studies)

Günümüze kadar güneş ışınımı tahmini konusunda birçok çalışma gerçekleştirilmiştir. Yapılan bu çalışmalar sonucunda araştırmacılar tarafından güneş ışınımı tahmininde etkin bir şekilde kullanılabilecek

farklı yöntemler ortaya konmuştur. Kara [4] günlük güneş ışınımı tahmini için, Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ağlarından oluşan bir model önermiştir. Modelin eğitimi ve performans değerlendirilmesinde 1983 ile 2018 tarihleri arasındaki Çorum iline ait 12969 adet günlük güneş ışınım verileri kullanmıştır. Yapılan deneysel çalışmalar, önerilen LSTM modelinin diğer makine öğrenmesi modellerine oranla daha başarılı tahminler gerçekleştirdiğini ortaya koymuştur. Arslan vd. [5] Mersin ilinde ölçülen 1 yıllık günlük toplam global güneş ışınım değerlerini kullanarak, Yapay Sinir Ağı (Artificial Neural Network - ANN) modelinin güneş ışınımı tahmin performansını incelemiştir. Oluşturulan ANN modelinde r^2 0,75 ve MAPE değeri % 27,67 olarak hesaplanmıştır. Ghimire vd. [6] yarım saatlik güneş ışınımı tahmini için Evrişimli Sinir Ağı (Convolutional Neural Network - CNN) ve LSTM ağlarından oluşan hibrit bir model geliştirmişlerdir. Güneş ışınımı tahmini için, Avustralya'da bulunan Alice Springs şehrinin 2006-2018 yılları arasındaki güneş ışınım verilerini kullanmışlardır. Önerilen hibrit model Derin Öğrenme, Tek Gizli Katman ve Ağaç tabanlı modellerle kıyaslanmıştır. Geliştirilen hibrit model, RRMSE = %1,515, MAPE = %4,672 ve APB = %1,233 ile 1 günlük yarım saatlik güneş ışınımı tahmini için en iyi performans göstermiştir. Kumari ve Toshniwal [7] CNN ve LSTM ağlarından oluşan hibrit bir model önermişlerdir. Hibrit model ABD'de California Eyaleti'nin 23 lokasyonunun meteorolojik verileri kullanılarak eğitilmiştir. Önerilen hibrit LSTM-CNN modeli ilk olarak zaman serisi güneş ışınımı verilerinden zamansal özellikleri çıkarmak için LSTM'yi kullanır, ardından CNN, hedefin ve komşu konunun birkaç meteorolojik değişkeninin korelasyon matrisinden uzamsal özellikleri çıkarır. Hibrit LSTM-CNN modeli, diğer bağımsız modeller (SP, ANN, SVM, LSTM, CNN) ile karşılaştırıldığında %37 ile %45 arasında değişen oranlarda daha iyi performans göstermiştir. Jalali vd. [8] güneş ışınımı tahmini için CNN modellerini kullanan yeni bir topluluk öğrenme stratejisini sunmaktadır. Metot, farklı veri varyasyonlarını kullanarak birden fazla model eğitmekte ve sonra tahminlerini birleştirerek genel tahmin doğruluğunu artırmaktadır. Ayrıca, CNN modellerinin optimize edilmesi ve böylelikle daha iyi performans gösterebilmeleri için bir optimizasyon algoritması önermişlerdir. Çalışmanın sonuçları, önerilen topluluk yaklaşımının tahmin doğruluğu açısından tek model metodlarını geride bıraktığını göstermiştir. Haider vd. [9] Islamabad şehrinde kısa ve uzun vadeli güneş ışınımı tahmini için derin öğrenme ve istatistiksel yöntemlerin kullanımını incelemiştir. Çalışmalarında özellikle kullanılan verilerin ön işleme süreçleri, veri setinin hazırlanması, derin öğrenme modellerinin eğitimi ve istatistiksel yöntemlerin uygulanması gibi aşamaları ele almışlardır. Bu yöntemler arasında, LSTM, Kapı Özyinelemeli Geçitler (Gated Recurrent Units - GRU) ve CNN gibi derin öğrenme modelleri kullanmışlardır. Çalışmanın sonucunda ANN, CNN ve LSTM mimarilerinin en iyi performansı gösterdiğini belirlemişlerdir. Gao vd. [10] saatlik güneş ışınımı tahmini için CEEMDAN ve çoklu-strateji CNN-LSTM sinir ağları temelli yeni bir yöntem önermişlerdir. Çalışmada, öncelikle CEEMDAN adı verilen bir yöntem kullanarak veriler ön işleme tabii tutulmaktadır. Bu yöntem, verileri parçalara ayırarak, içerisindeki farklı frekanslardaki sinyalleri ayrı ayrı incelemeye olanak sağlamaktadır. Daha sonra, bu ön işlem yapılmış veriler kullanılarak CNN-LSTM sinir ağları eğitimi gerçekleştirilmiştir. Bu yöntem ile elde edilen tahminler, diğer tahmin metodları ile karşılaştırılmakta ve performansları analizleri gerçekleştirilmiştir. Analizler sonucunda, saatlik güneş ışınımı tahmini için CEEMDAN ve CNN-LSTM temelli çoklu-strateji yönteminin etkili olduğunu ve bu yöntemin güneş ışınımı tahmininde kullanılabileceğini ortaya koymuşlardır. Açıköz vd. [11] kısa vadeli güneş ışınımı tahmini için CNN ve derin öznitelik seçimi bazlı yeni bir yaklaşım sunmuşlardır. Çalışma, veri setinde öznitelik seçimi yaparak, sadece en önemli öznitelik kullanarak tahmin yapmayı amaçlamaktadır. Öznitelik seçimi için derin öğrenme tabanlı bir

yöntem kullanmışlardır. Ardından seçilen öznelikler kullanılarak Evrişimli Sinir Ağları eğitimi gerçekleştirilmiştir. Deneysel çalışmalar sonucunda elde edilen bulgular, diğer tahmin yöntemlerinin sonuçları ile karşılaştırılmış ve önerilen yöntemin kısa vadeli güneş ışınımı tahmini için etkili olduğu belirlenmiştir.

3. Metodoloji: Zaman Serisi Tahmini ve Derin Öğrenme (Methodology: Time Series Prediction and Deep Learning)

Herhangi bir işleme göre belirli aralıklarla ölçülmüş olan ardışık verilere zaman serisi denmektedir. Zaman serileri için kullanılan aralıklar eşit olmak koşuluyla farklı boyutlarda olabilmektedir. Genellikle saatlik, günlük, aylık veya yıllık olarak ölçülmektedir. Zaman serisi tahmini ise geçmişe ait zaman serisi değerlerini kullanarak gelecek verilerin tahmin edilmesidir [12].

Zaman serisi tahmin modelleri doğrusal ve doğrusal olmayan tahmin modelleri olmak üzere ikiye ayrılabilir. Doğrusal modeller geçmiş gözlemlerin doğrusal bileşimini alarak tahminler üretmektedir. Bu modellere örnek olarak ARMA, ARIMA gösterilebilir. Doğrusal olmayan modeller ise doğrusal modellerin yetersiz kaldığı karmaşık ilişkilerin yer aldığı problemlerin çözümünde veya verilerin çok değişkenli olduğu durumlarda kullanılmaktadır. Doğrusal olmayan modellere örnek olarak ise ANN, Karar ağaçları ve Destek Vektör Makineleri (Support Vector Machine - SVM) verilebilir [12, 13].

Aşağıda verilen alt başlıklarla birlikte bu makalede izlenen metodoloji sunulmuştur. Bu kapsamda ilk olarak 3.1’de kullanılan veri, 3.2’de CNN ağları, 3.3’de LSTM ağları son olarak 3.4’de deneylerde kullanılan performans metrikleri aktarılmıştır.

3.1. Kullanılan Veri (Data Used)

Bu çalışmada kullanılan güneş ışınımı verileri Kipp&Zonen marka CMP-6 model bir piranometre aracılığıyla toplanmıştır. Piranometre, Afyon Kocatepe Üniversitesi GÜRAM bünyesine yerleştirilmiş ve ölçümler 1 Ocak 2012 – 31 Aralık 2013 aralığında saatlik olarak gerçekleştirilmiştir. Piranometre, 64 ısı çift bileşenlerini algılayabilen, 5-20 $\mu\text{VW}^{-1}\text{m}^2$ ölçme hassasiyeti bulunan bir yapıya sahiptir. 1 Ocak 2012 – 31 Aralık 2012 tarihleri arasında

Afyonkarahisar ilinde ölçülen güneş ışınımı değerleri Şekil 1’de görülebilmektedir.

Şekil 1 incelendiğinde, güneş ışınımı değerlerinin herhangi bir düzenli değişim veya eğilim göstermediği, bununla birlikte farklı nedenlerle beklenmedik ani düşüşlerin meydana geldiği görülebilmektedir. Bu nedenle, yüksek varyanslı güneş ışınımı verilerini modellemek oldukça karmaşık bir problem ve doğrusal olmayan yöntemler gereklidir.

3.2. Evrişimli Sinir Ağları (Convolutional Neural Network - CNN)

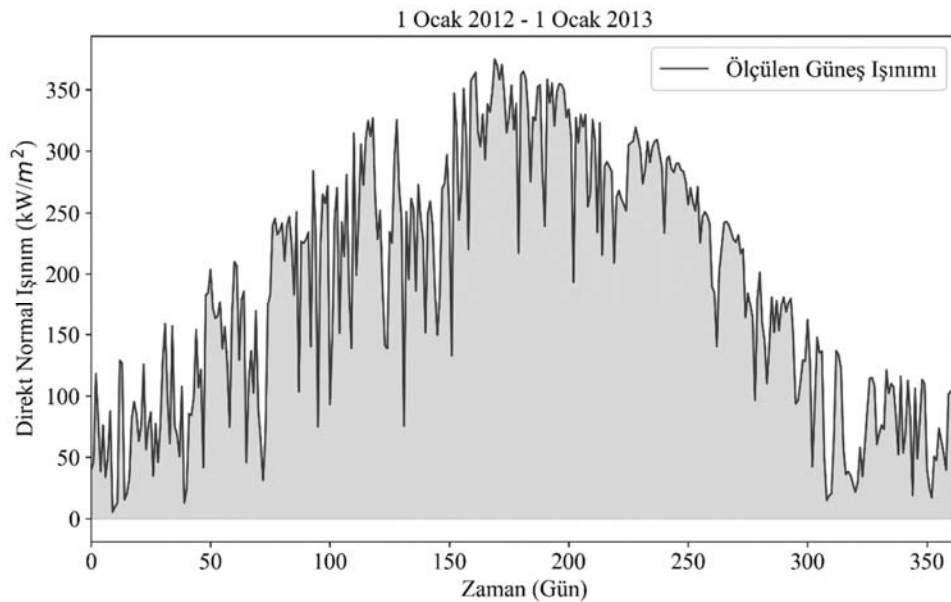
CNN Lecun vd. tarafından 1998 yılında önerilen bir derin öğrenme modelidir [14]. Görüntü ve doğal dil işlemede yüksek performansa sahip ileri beslemeli sinir ağıdır ve zaman serilerinin tahmininde etkili bir şekilde kullanılabilir [15]. CNN, evrişim katmanı, havuzlama katmanı ve tam bağlı katman olmak üzere 3 bölümden oluşmaktadır. Her evrişim katmanı çok sayıda evrişim filtresi içerir ve bu filtrelere ait hesaplamalar Eş. 1’de verilen formül kullanılarak gerçekleştirilmektedir.

$$l_t = \tanh(x_t * k_t + b_t) \quad (1)$$

Denklemde l_t evrişim işleminden sonraki çıktı değerini, \tanh aktivasyon fonksiyonunu, x_t giriş vektörünü, k_t evrişim filtresinin ağırlığını, b_t ise bias değerini ifade etmektedir. Evrişim katmanında gerçekleştirilen evrişim işlemi ile verilere ait öznelikler çıkartılmaktadır. Ancak çıkartılan öznelik boyutları çok yüksektir. Bu sorunun üstesinden gelmek ve ağırlık eğitim maliyetlerini azaltabilmek amacıyla havuzlama katmanı kullanılmaktadır. Bu katman sayesinde, sinir ağına doğru kararlar verebilmesi için gerekli bilgileri içeren öznelikler seçilerek veri boyutu azaltılmaktadır. "Son olarak evrişim ve havuzlama katmanlarından gelen matrisler tek boyutlu diziyeye çevrilerek tam bağlı katmanlara verilmektedir.

3.3. Uzun-Kısa Süreli Bellek Ağları (Long Short-Term Memory - LSTM)

Uzun-kısa süreli bellek ağları, sıralı verileri işlemek için geliştirilmiş Tekrarlayan sinir ağları (Recurrent neural network - RNN)’lerin özel bir türü olarak 1990’lı yılların sonlarında geliştirilmiştir. RNN’ler ileri



Şekil 1. 1 Ocak 2012-1 Ocak 2013 tarihleri arasında Afyonkarahisar’da ölçülen günlük ortalama güneş ışınımı değerleri (Daily average solar radiation values measured in Afyonkarahisar between January 1, 2012, and January 1, 2013)

beslemeli sinir ağlarından farklı olarak geri besleme bağlantıları bulundurmaktadır. Böylelikle zamansal işlemler gerçekleştirebilmekte ve sıralı dizileri öğrenebilmektedirler. Gizli katmanın bir bellek görevi görmesi ile birlikte sıralı bilgiler saklanabilmekte, bir diğer katmana aktarılabilir [12]. Ancak katman sayısına göre katlanarak artan/azalan gradyan değerleri nedeniyle gradyan kaybolması/patlanması sorununun yaşanabildiği bu nedenle, uzun vadeli bağımlılıkların yakalanamadığı tespit edilmiştir [16, 17]. Sonrasında yapılan çalışmalar sonucunda, uzun süreli bilgileri hatırlamak ve bu sorunu çözmek için LSTM mimarisi tasarlanmıştır.

LSTM'ler içerdikleri kapılar ile birlikte uzun vadeli bilgileri takip edebilmektedir. Bir LSTM ünitesinde hangi bilgilerin unutulacağı, hangi bilgilerin saklanacağını belirleyen kapılar bulunmaktadır. Bu kapılar giriş kapısı, unutma kapısı ve çıkış kapısıdır. Giriş kapısı gelen giriş değerinden hangisinin yeni durumda saklanacağını, unutma kapısı ise geçmiş durum bilgilerinden hangisinin artık saklanmayacağını belirlemektedir. Son olarak çıkış kapısı yeni durumdaki bilgilerden hangisinin çıktı olarak gönderileceğini belirlemektedir. LSTM birimini oluşturan kapılar Şekil 2'de görülebilmektedir. Şekilde C birim durumunu, \hat{C} sonraki aday durumunu, i, f ve o harfleri de sırasıyla giriş kapısı, unutma kapısı ve çıkış kapısını temsil etmektedir [12].


3.4. Önerilen Model, Karşılaştırma Modelleri ve Performans Ölçütleri

(Proposed Model, Comparison Models And Performance Metrics)

Önerilen CNN-LSTM hibrit modeli Evrişimli Sinir Ağı ve Uzun-Kısa Süreli Bellek ağlarını birleştiren hibrit bir derin öğrenme mimarisidir. Bu hibrit mimaride ilk olarak girdi verilerinden yararlı özelliklerin çıkarılması amacıyla evrişim katmanları kullanılmaktadır. Ardından çıkarılan yararlı özellikler LSTM katmanlarına girdi olarak verilmektedir. LSTM katmanları kullanarak sıralı veriler işlenebilmekte ve uzun vadeli bilgiler öğrenilebilmektedir. Son olarak LSTM katmanlarından gelen çıktı tam bağlı katmanlara (Fully Connected Layer) verilmekte ve ışınım tahminlerine ulaşılmaktadır. Şekil 3'de çalışmada kullanılan hibrit mimariye ait genel yapı görülebilmektedir.

Gün içi ortalama güneş ışınımı tahmini için önerilen CNN-LSTM modelinin etkililiği ve performansının incelenmesi amacıyla, bazı makine öğrenimi algoritmaları ile birlikte geleneksel istatistiksel bir yöntem seçilmiştir. Seçilen bu algoritmaların çıktıları, farklı istatistiksel değerlendirme kriterleri kullanılarak CNN-LSTM modelinin çıktıları ile karşılaştırılmıştır. Bu amaç doğrultusunda literatürde yaygın kullanımları ve performansları dikkate alarak, Karar Ağaçları Regresyon (DTR), Rastgele Orman Regresyon (RF)

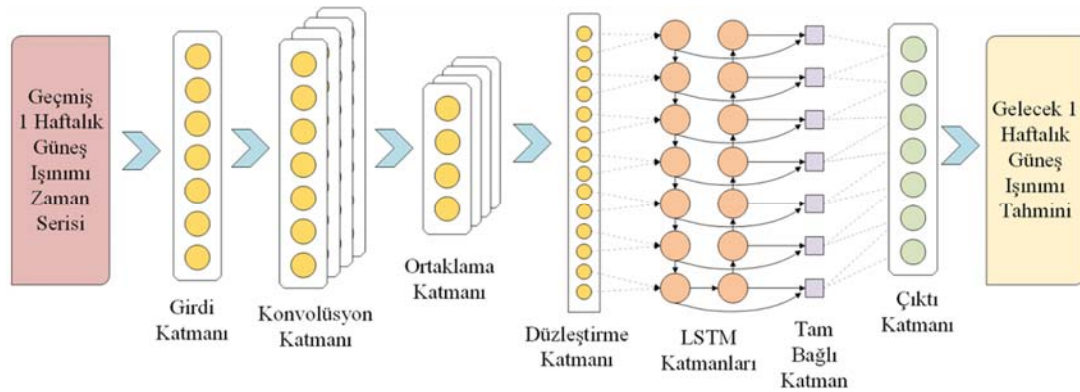
ve K-En Yakın Komşu (KNN) makine öğrenimi algoritmaları ve Bütünleşik Otoregresif Hareketli Ortalama (ARIMA) geleneksel istatistiksel yöntemi tercih edilmiştir. Seçilen makine öğrenmesi algoritmalarında kullanılan parametreler Bouktif vd. tarafından gerçekleştirilen çalışma dikkate alınarak belirlenmiştir [18]. ARIMA istatistiksel yönteminde kullanılan parametreler ise deneysel çalışmalar sonucunda deneme yanılma yolu ile belirlenmiştir. Kullanılan parametre değerleri Tablo 1'de görülebilmektedir.



Şekil 2. LSTM birimi ve kapılar (LSTM unit and doors) [12].

Tablo 1. Karşılaştırma amacıyla seçilen algoritmalarda kullanılan parametre değerleri
(Parameter values used in selected algorithms for comparison)

Model	Parametreler
Karar Ağaçları Regresyon	Ağaç Maksimum Derinliği: 100 Minimum Samples Split: 4 Minimum Sample Leaf:4 Ağaç Sayısı: 125
Rastgele Orman Regresyon	Ağaç Maksimum Derinliği: 100 Minimum Samples Split: 4 Minimum Sample Leaf:4 Komşu Sayısı: 5
K-En Yakın Komşu	Ağırlık Fonksiyonu: Uniform Mesafe Ölçütü: Öklid Gecikme Gözlemleri Sayısı: 7
Bütünleşik Otoregresif Hareketli Ortalama	Fark Derecesi: 0 Hareketli Ortalama Penceresi Boyutu: 1



Şekil 3. Önerilen hibrit derin öğrenme modeli akış şeması (Proposed hybrid deep learning model flow chart)

Çalışmada yer alan makine öğrenmesi algoritmaları ve önerilen CNN-LSTM modelinde kayıp fonksiyonu olarak Ortalama Hata Kareleri (Mean Squared Error - MSE) kullanılmıştır. Kayıp fonksiyonu yardımıyla gerçek değerler ve tahmin değerleri arasındaki fark minimize edilerek en uygun model parametreleri belirlenmektedir. Eş. 2'de kullanılan MSE kayıp fonksiyonuna ait formül verilmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (o_i - p_i)^2 \quad (2)$$

Önerilen CNN-LSTM model mimarisi sırasıyla bir girdi katmanı (input layer), 128 filtre ve 3 çekirdek boyutlu evrişim katmanı (conv1d), ortaklama boyutu 2 olan maksimum ortaklama katmanı (maxpooling), düzleştirme (flatten) katmanı, 64 nörona sahip LSTM katmanı, 0.1 oranında seyreltme (dropout) katmanı, 32 nörona sahip LSTM katmanı, 0.1 oranında seyreltme katmanı, relu aktivasyon fonksiyonuna sahip 16 nörondan oluşan tam bağlı katman (dense) ve son olarak 1 nörondan oluşan tam bağlı katmandan oluşmaktadır. Girdi katmanı geçmiş 7 günlük (1 hafta) ortalama güneş ışınım değerlerini kullanmaktadır. Optimizasyon algoritması olarak ADAM algoritması tercih edilmiş, öğrenme oranı 0.0001 seçilmiştir. Modelin eğitimi için epoch değeri 250 olarak belirlenmiş ve öğrenme oranı her bir epoch'da öğrenme oranı/epoch değeri kadar küçültülmüştür. Yığın sayısı (batch size) 32 olarak belirlenmiştir. Ayrıca her bir epoch sonrasında doğrulama kayıp (validation loss) değeri kontrol edilerek belirli bir epoch boyunca kaybın azalmaması durumunda erken durdurma devreye sokularak eğitim durdurulmuştur.

CNN-LSTM modelinin tahmin performansını değerlendirebilmek amacıyla dört farklı istatistiksel değerlendirme ölçütünden yararlanılmıştır. Bu ölçütlerin isimleri ve ilgili eşitlikler aşağıda sunulmuştur.

Ortalama Mutlak Hata (Mean absolute error - MAE): Gerçek değerler ile tahmin değerleri arasındaki farkın ortalama mutlak sapması olarak tanımlanmaktadır. Hesaplama yararlanan formülizasyon Eş. 3'de verilmiştir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |o_i - p_i| \quad (3)$$

Ortalama Karekök Hata (Root mean square error - RMSE): Tahmin hatalarının standart sapması olarak ifade edilmektedir. Eş. 4'de verilen formülizasyon kullanılarak hesaplanmaktadır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (o_i - p_i)^2}{N}} \quad (4)$$

Ortalama Mutlak Yüzde Hata (Mean absolute percentage error - MAPE): Tahmin doğruluğunu yüzdesel olarak hesaplamak amacıyla kullanılır. Eş. 5'de verilen formülizasyon kullanılarak hesaplanmaktadır.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{o_i - p_i}{o_i} \right| \quad (5)$$

Belirleme (Determinasyon) Katsayısı (coefficient of determination - r^2): Örnekte hesaplanan regresyon denkleminin verilere uyum düzeyini göstermektedir. Başka bir deyişle tahmin ve gerçek değerler arasındaki lineer ilişkinin gücünü ifade etmektedir. Eş. 6'da verilen formülizasyon kullanılarak hesaplanmaktadır.

$$r^2 = 1 - \frac{\sum_{i=1}^N (o_i - p_i)^2}{\sum_{i=1}^N (o_i - \bar{o})^2} \quad (6)$$

Denklemlerde N , örnek sayısını, o_i i. gözlem değerini, p_i i. tahmin değerini ve \bar{o} gerçek gözlem değerlerinin ortalamasını ifade etmektedir.

4. Deneysel Çalışmalar (Experimental Studies)

Bu bölümde, ölçülen güneş ışınımı verileri kullanılarak önerilen CNN-LSTM modelinin uygulanabilirliği ve performansı incelenmiştir. Bölüm 4.1'de veri hazırlama sürecine, bölüm 4.2'de ise deney sonuçlarına yer verilmiştir.

4.1. Verinin Hazırlanması (Data Preparation)

CNN-LSTM modelinin performansını arttırabilmek ve modelin eğitim ve testlerini gerçekleştirebilmek için güneş ışınımı verisi bazı ön işlemlerden geçirilmiştir. İlk olarak 2012 ve 2013 yılları için saatlik olarak ölçümleri gerçekleştirilen verilerin 24 saatlik ortalamaları alınarak günlük ortalama güneş ışınımı değerlerine ulaşılmıştır. 2012 yılında toplanan veriler modelin eğitiminde, 2013 yılında toplanan veriler ise modelin testinde kullanılmıştır. Ayrıca eğitim için ayrılmış olan 2012 verilerinin %25'i model hiper parametrelerinin en optimum değerlerine ayarlanabilmesi amacıyla validasyon için ayrılmıştır. Böylelikle 274 günlük ortalama güneş ışınımı verisi ağız eğitiminde, 91 günlük veri ağız validasyonunda, 365 günlük veri ise modelin test edilmesinde kullanılmıştır.

Çalışma kapsamında önerilen modelin geçmiş 7 günlük ortalama güneş ışınımı değerini kullanarak gelecek 7 günlük ortalama güneş ışınımı değerini tahmin etmesi hedeflenmiştir. Bu nedenle gecikme (lag) değeri 7 olarak belirlenmiş ve eğitim için ayrılmış zaman serisine 7 günlük gecikme uygulanmıştır. Sonuç olarak girdi verisinde geçmiş 7 günlük (1 hafta) ortalama güneş ışınımı ve çıktı verisinde gelecek 7 günlük güneş ışınımı bulunan veri setine ulaşılmıştır. Çalışmada yer alan tüm modellerde edilen bu veri seti kullanılmış ve tahminler gerçekleştirilmiştir.

4.2. Deney Sonuçları (Experiment Results)

Bu bölümde, günlük ortalama güneş ışınımı tahmini için önerilen CNN-LSTM hibrit derin öğrenme modelinin analizi ve değerlendirilmesi için gerçekleştirilen deneysel çalışmalardan elde edilen sonuçlardan bahsedilecektir. Bu kapsamda ilk olarak CNN-LSTM hibrit derin öğrenme modelinin tahmin sonuçları ARIMA istatistiksel yöntemi ve diğer makine öğrenmesi yöntemlerinin tahmin sonuçlarıyla karşılaştırılmıştır. Karşılaştırmalarda performans ölçütleri başlığında detaylı olarak verilen RMSE, MAE, MAPE ve r^2 istatistiksel değerlendirme ölçütlerinden yararlanılmıştır. Tablo 2'de her bir tahmin modeli için elde edilen ölçüt değerleri verilmiştir. DTR modeli diğer modellere oranla RMSE ve r^2 performans metriklerinde en düşük başarıyı gösterdiği için temel model olarak kabul edilmiş, diğer modellerin performansları DTR modeli baz alınarak değerlendirilmiştir. Tabloda "değer" satırlarında istatistiksel değerlendirmeler sonucu elde edilen ölçüt değer sonuçları, "değişim" satırlarında ise temel modele göre hesaplanan değişim değerleri verilmiştir.

Tablo 2. Modellerin performans karşılaştırması (Performance comparison of models)

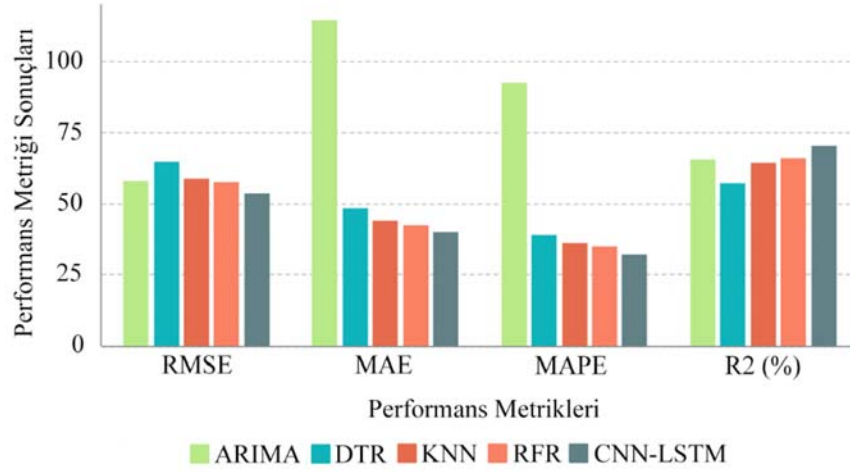
Model		RMSE	MAE	MAPE	r^2 (%)
DTR	Değer	64,944	48,581	39,316	57,503
	Değişim (%)	8,78	8,57	7,14	12,42
KNN	Değer	59,236	44,415	36,507	64,645
	Değişim (%)	8,78	8,57	7,14	12,42
ARIMA	Değer	58,301	114,516	92,610	65,753
	Değişim (%)	10,22	-135,72	-135,55	14,347
RFR	Değer	57,859	42,597	35,031	66,343
	Değişim (%)	10,90	12,31	10,89	15,37
CNN-LSTM	Değer	53,955	40,196	32,536	70,668
	Değişim (%)	16,92	17,25	17,24	22,89

Sonuçlar incelendiğinde, tüm istatistiksel ölçütlerde önerilen CNN-LSTM modelinin ARIMA istatistiksel yöntemi ve diğer makine öğrenmesi yöntemlerine oranla daha başarılı sonuçlar elde ettiği görülebilmektedir. CNN-LSTM hibrit derin öğrenme modeli 53,955 RMSE, 40,196 MAE, 32,536 MAPE ve %70,668 r^2 ölçüt değerleriyle tahminler gerçekleştirmiştir. Temel model olarak kabul edilen DTR modeline oranla dört farklı ölçüt için ortalama %18,57, r^2 ölçüt değerlerine oranla ise %22,89 daha başarılı tahminler gerçekleştirmiştir. Önerilen CNN-LSTM modelinin ardından en başarılı tahminleri üreten makine öğrenmesi modeli 57,859 RMSE, 42,597 MAE, 35,031 MAPE, %66,343 r^2 değerleriyle Rastgele Orman Regresyon olmuştur. Şekil 4’de her bir model için elde edilen performans ölçütü değerleri grafiksel olarak gösterilmiştir.

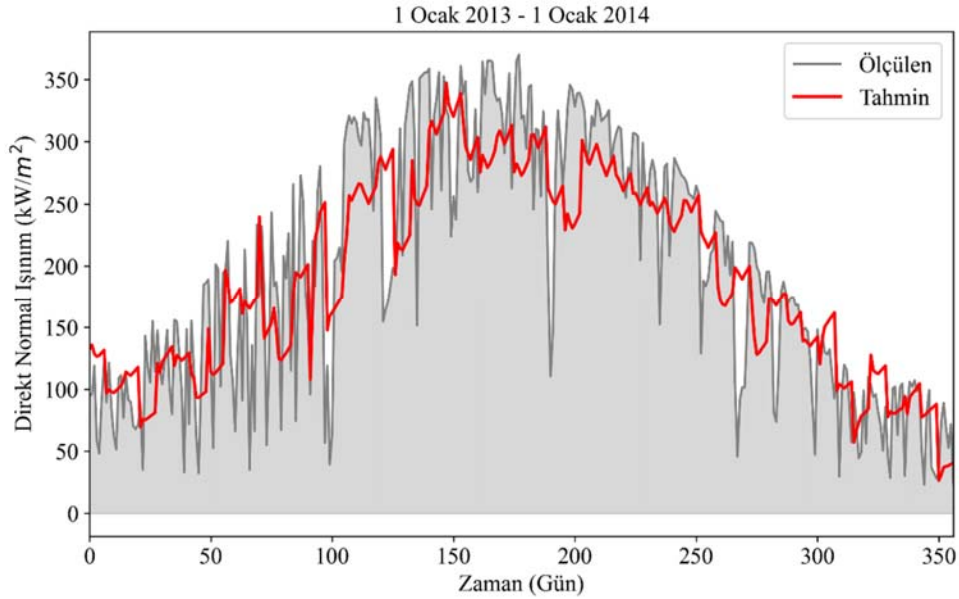
Grafik incelendiğinde önerilen derin öğrenme hibrit modelinin RMSE, MAE, MAPE hata ölçütlerinde ARIMA istatistiksel modeli ve diğer makine öğrenmesi yöntemlerine oranla en düşük değerleri verdiği görülebilmektedir. Ayrıca gerçek değerlerle tahmin

değerlerinin uyumluluğunu gösteren ve belirlilik katsayısı olarak adlandırılan r^2 değerinde en yüksek yüzdelik değeri vermiştir. Karar ağaçları modeli ise RMSE ve r^2 performans metrikleri dikkate alındığında en başarısız tahminleri gerçekleştiren, dolayısıyla en kötü performansı gösteren yöntem olmuştur. Çalışmada yer alan modellerin performans sıralamaları ise r^2 performans metriği dikkate alındığında sırasıyla CNN-LSTM, Rastgele Orman Regresyon, ARIMA, K-En Yakın Komşu ve Karar Ağaçları olarak belirlenmiştir. Son olarak, Şekil 5’de CNN-LSTM modeli kullanılarak 2013 yılı için gerçekleştirilen gün içi ortalama güneş ışınımı tahmin sonuçları verilmiştir.

Grafikte gri renk ile gösterilen değerler 1 Ocak 2013 – 1 Ocak 2014 tarihleri arasında ölçülen ortalama gün içi güneş ışınımı test değerlerini, kırmızı renk ile gösterilen değerler ise önerilen CNN-LSTM hibrit modelinin tahmin sonuçlarını ifade etmektedir. Grafik incelendiğinde, modelin gerçek değerlerle oldukça tutarlı tahminler gerçekleştirebildiği görülebilmektedir. Belirli alanlardaki ani



Şekil 4. Modellere ait performans ölçütlerinin grafiksel gösterim (Graphical display of performance criteria of models)



Şekil 5. 1 Ocak 2013 ve 1 Ocak 2014 tarihleri arasında ölçülen gün içi ortalama güneş ışınımı değerleri ve önerilen CNN-LSTM modelinin tahmin değerleri (The average intraday solar radiation values measured between January 1, 2013, and January 1, 2014, and the predicted values of the proposed CNN-LSTM model)

düşüşlerin model tarafından kısmi olarak yakalanabildiği, genel olarak gerçek değerlerle tahmin değerlerinin aynı eğilimde olduğu gözlenmiştir. Sonuç olarak, gün içi ortalama güneş ışınımı değeri tahmininde, önerilen CNN-LSTM tahmin modelinin etkin bir şekilde kullanılabileceği sonucuna ulaşılmıştır.

5. Sonuçlar (Conclusions)

Bu çalışmada, gün içi ortalama güneş ışınımı tahmini için CNN ve LSTM ağlarından oluşan hibrit bir derin öğrenme modeli geliştirilerek yöntemin performansı ve uygulanabilirliği araştırılmıştır. Önerilen modelin eğitim, test ve performans değerlendirmesi aşamalarında Afyonkarahisar ilinde 1 Ocak 2012 – 1 Ocak 2014 tarihleri arasında ölçümü gerçekleştirilen ışınım verileri kullanılmıştır. Önerilen modelden elde edilen sonuçlar, modelin performansının değerlendirilebilmesi amacıyla geleneksel istatistiksel yöntemlerden biri olan ARIMA ve en gelişmiş makine öğrenmesi algoritmalarından olan Rastgele Orman Regresyon, K-En Yakın Komşu ve Karar Ağaçları modellerinin sonuçları ile karşılaştırılmıştır. Gerçekleştirilen deneysel çalışmaların sonucunda, önerilen CNN-LSTM hibrit derin öğrenme modelinin RMSE, MAE, MAPE ve r^2 istatistiksel değerlendirme ölçütlerinin tümünde diğer modellere oranla daha başarılı sonuçlar verdiği ortaya konmuştur. Modellerin tahmin performansları incelendiğinde ise en başarılıdan en başarısız sıralamanın sırasıyla CNN-LSTM, Rastgele Orman Regresyon, ARIMA, K-En Yakın Komşu ve Karar Ağaçları olduğu belirlenmiştir. CNN-LSTM modeli, Karar Ağaçları modeli ile karşılaştırıldığında RMSE, MAE, MAPE ve r^2 değerlendirme ölçütlerinde sırasıyla %16,92, %17,25, %17,24, %22,89 düzeyinde daha başarılı sonuçlar elde etmiştir.

Sonuçlar incelendiğinde, önerilen hibrit modelin geliştirilmeye açık yönleriyle birlikte günlük ortalama güneş ışınımı tahmininde etkin bir şekilde kullanılabileceği ortaya konmuştur. Buna ek olarak, derin öğrenme modellerinin çok sayıda veriye ihtiyaç duymaları nedeniyle veri sayısının artırılmasıyla birlikte model performansının arttırılabileceği öngörülmektedir. Ayrıca, model içerisinde yer alan parametrelerin optimize edilmesi ve güneş ışınımı değeri ile ilintili farklı zaman serilerinin tahmin sürecine dahil edilmesiyle model performansının arttırılabileceği düşünülmektedir.

Kaynaklar (References)

- Öztürk H., Dünyada ve Türkiye'de güneş enerjisinden elektrik üretimi: güncel piyasa gelişmeleri ve beklentiler, 2022.
- Chu Y, Pedro H.T, Coimbra C.F., Hybrid intra-hour DNI forecasts with sky image processing enhanced by stochastic learning, Solar Energy, 98, 592-603, 2013.
- Qing X, Niu Y., Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM, Energy, 148, 461-8, 2018.
- Kara A., Global solar irradiance time series prediction using long short-term memory network, Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji, 4, 7, 2019.
- Arslan G., Bayhan B., Yaman K., Mersin/Türkiye için ölçülen global güneş ışınımının yapay sinir ağları ile tahmin edilmesi ve yaygın ışınım modelleri ile karşılaştırılması, Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji, 7, 80-96, 2019.
- Ghimire S., Deo R.C., Raj N., Mi J., Deep solar radiation forecasting with convolutional neural network and long short-term memory network algorithms, Applied Energy, 253, 113541, 2019.
- Kumari P., Toshniwal D., Long short term memory-convolutional neural network based deep hybrid approach for solar irradiance forecasting, Applied Energy, 295, 117061, 2021.
- Jalali S.M.J., Khodayar M., Ahmadian S., Shafie-Khah M., Khosravi A., Islam S.M.S, A new ensemble reinforcement learning strategy for solar irradiance forecasting using deep optimized convolutional neural network models, 2021 International Conference on Smart Energy Systems and Technologies (SEST): IEEE, 1-6, 2021.
- Haider S.A., Sajid M., Sajid H., Uddin E., Ayaz Y., Deep learning and statistical methods for short-and long-term solar irradiance forecasting for Islamabad, Renewable Energy, 198, 51-60, 2022.
- Gao B., Huang X., Shi J., Tai Y., Zhang J., Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks, Renewable Energy, 162, 1665-83, 2020.
- Acikgoz H., A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting, Applied Energy, 305, 117912, 2022.
- Sorkun M.C., Incel Ö.D., Paoli C., Time series forecasting on multivariate solar radiation data using deep learning (LSTM), Turkish Journal of Electrical Engineering and Computer Sciences, 28, 211-23, 2020.
- Erturan M.B., Merdivenci F., Optimized ARIMA-ANN hybrid model for time series analysis, Journal of the Faculty of Engineering and Architecture of Gazi University, 37 (2), 1019-1032, 2022.
- LeCun Y., Bottou L., Bengio Y., Haffner P., Gradient-based learning applied to document recognition, Proceedings of the IEEE, 86, 2278-324, 1998.
- Qin L., Yu N., Zhao D., Applying the convolutional neural network deep learning technology to behavioural recognition in intelligent video, Tehnički vjesnik, 25, 528-35, 2018.
- Pascanu R., Mikolov T., Bengio Y., On the difficulty of training recurrent neural networks, International conference on machine learning: PMLR, 1310-8, 2013.
- Begüm E., İnkaya T., Long short-term memory network based deep transfer learning approach for sales forecasting, Journal of the Faculty of Engineering and Architecture of Gazi University, 39 (1), 191-202, 2024.
- Bouktif S., Fiaz A., Ouni A., Serhani M.A., Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches, Energies, 11, 1636, 2018.