



Estimation of Monthly Global Solar Radiation Using Long-Short Term Memory (LSTM) Method: A Case Study of Sivas Province

Cahit Gürlek^{1,a*}, Mehmet Bilgili^{2,b}

¹ Department of Mechanical Engineering, Engineering Faculty, Sivas Cumhuriyet University, Sivas, Turkey

² Department of Mechanical Engineering, Ceyhan Engineering Faculty, Cukurova University, Adana, Turkey,

*Corresponding author

Research Article

History

Received: 25/03/2023

Accepted: 25/04/2023

ABSTRACT

Accurate estimation of global solar radiation is critical for solar energy conversion systems (modelling, design and operation) and future investment policies. In this study, daily average monthly solar radiation estimation were performed using the long-short term memory (LSTM) method. For this aim, monthly sunshine radiation data obtained from the Sivas Province in the Central Anatolia Region of Turkey was used. Mean absolute percent error (MAPE), root mean square error (RMSE) and correlation coefficient (*R*) tests were used for forecast accuracy assessment. The results showed that the LTSM model predicted solar radiation effectively with MAPE of 9.446%, RMSE of 0.496 kWh/m²/day, and *R* of 0.976 for the study area.

Keywords: LSTM, Machine Learning, Monthly Solar Radiation, Sivas

Aylık Toplam Güneş Işınımının Uzun-Kısa Süreli Bellek (LSTM) Yöntemiyle Tahmini: Sivas İli Örneği

Öz

Süreç

Geliş: 25/03/2023

Kabul: 25/04/2023

Küresel güneş ışınımının doğru tahmini, güneş enerjisi dönüşüm sistemleri (modelleme, tasarım ve işletme) ve gelecekteki yatırım politikaları için kritik bir öneme sahiptir. Bu çalışmada uzun-kısa süreli bellek (LSTM) yöntemi kullanılarak günlük ortalama aylık güneş ışınımı tahmini yapılmıştır. Bunun için Türkiye'nin İç Anadolu Bölgesinde bulunan Sivas ilinden elde edilen aylık güneş ışınımı verileri kullanılmıştır. Tahmin doğruluğunu değerlendirmesi için ortalama mutlak yüzde hata (MAPE), kök ortalama kare hatası (RMSE) ve korelasyon katsayısı (*R*) testleri kullanılmıştır. Sonuçlar LSTM modelinin çalışma alanı için güneş ışınımını %9.446 MAPE, 0.496 kWh/m²/gün RMSE ve 0.976 *R* değerleri ile etkin bir şekilde tahmin ettiğini göstermektedir.

License



This work is licensed under
Creative Commons Attribution 4.0
International License

Anahtar Kelimeler: LSTM, Makine Öğrenmesi, Aylık Güneş Işınımı, Sivas

cugurlek@cumhuriyet.edu.tr

<https://orcid.org/0000-0002-0273-2999>

mbilgili@cumhuriyet.edu.tr

<https://orcid.org/0000-0002-5339-6120>

How to Cite: Gürlek C., Bilgili M. (2023) Estimation of Monthly Global Solar Radiation Using Long-Short Term Memory (LSTM) Method: A Case Study of Sivas Province, Journal of Science and Technology, 2(1):24-30.

Giriş

Fosil kaynaklı yakıtların sınırlı olması, elde edilme sürecinde ve tüketilmesi sonrasında çevre, ekosistem ve insan sağlığına verdiği yıkıcı zararlar ve bunlara ek olarak artan enerji tüketimi ve fiyatları nedeniyle alternatif enerji kaynaklarına olan ilgi her geçen gün artmaktadır. Güneş enerjisi dikkate alındığında 2011 ile 2021 yılları arasında kurulu fotovoltaik (PV) gücün yıllık büyümeye oranı dünya genelinde %27,9, Türkiye'de ise %102,6 seviyesindedir (BP, 2022).

Güneş ışınımı, güneş enerji sistemleri başta olmak üzere; ısıl konfor, güneş enerjisile ısıtma ve soğutma, endüstriyel ısıtma ve tarımsal üretim gibi birçok mühendislik uygulamasının tasarımını ve ekonomik değerlendirmesi için zorunlu bir veridir. Bununla birlikte daha çok ölçüm araçlarının kurulum ve bakımlarının pahalı olması nedeniyle yaygın olarak elde edilememektedir. Örneğin bu çalışmanın yapıldığı Sivas ili için 2010 yılından günümüze kadar sadece bir ölçüm istasyonu için tüm yıllara ait güneş ışınımı verileri bulunmaktadır. Bu nedenle güneş ışınımı; güneşlenme süresi, bağıl nem, sıcaklık, yağış miktarı, bulutluluk gibi daha yaygın olarak elde edilen meteorolojik veriler ya da daha önceki yıllarda ait güneş ışınımı verileri kullanılarak çeşitli yöntemlerle tahmin edilmektedir.

Güneş ışınımı tahmininde deneyisel (ampirik) modeller, yapay sinir ağları ve diğer makine öğrenme yöntemleri yaygın olarak kullanılmaktadır. Deneyisel yöntemleri; yalnızca güneşlenme süresinin kullanıldığı modeller, güneşlenme süresine sıcaklık gibi diğer meteorolojik verilerin eklenmesiyle oluşturulan modeller ve güneşlenme süresinin kullanılmadığı modeller olarak sınıflamak mümkündür. Makine öğrenme modelleri ise meteorolojik verilerin farklı bireşimlerinden oluşan girdiler, nöron ve katman sayıları, öğrenme algoritmaları ve transfer fonksiyonları gibi birçok değişkenin kullanıldığı çok daha karmaşık modellerdir (Zhang ve ark., 2017). Türkiye'nin farklı bölgeleri için çeşitli araştırmacılar tarafından hem deneyisel hem de makine öğrenme modelleriyle güneş

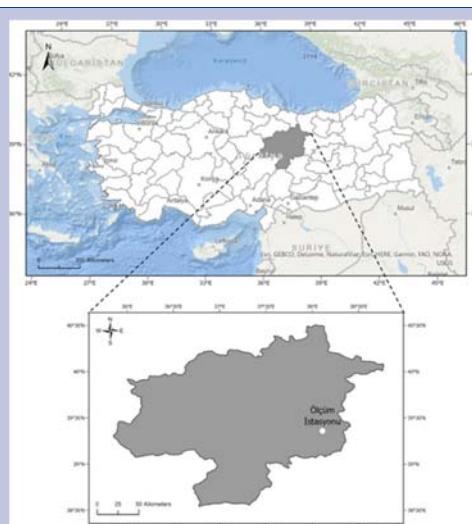
ışınımı tahminleri gerçekleştirılmıştır (Akinoglu ve Ecevit, 1990; Sözen ve ark., 2004; Şen ve ark., 2004; Sözen ve Arcaklıoğlu, 2005; Bakircı 2009; Şenkale ve Kuleli, 2009; Şenkale 2010; Koca ve ark., 2011; Bilgili ve Ozgoren, 2011; Ozgoren ve ark., 2012; Celik ve Muneer, 2013; Sahin ve ark., 2013; Yıldız ve ark., 2013; Gül ve Çelik, 2017; Gurlek ve Sahin, 2018; Arslan ve ark., 2019; Ballı, 2021). Bu çalışmarda makine öğrenme modellerinin deneyisel modellere göre daha iyi sonuçlar verdiği görülmektedir.

Bu çalışmada Uzun-Kısa Süreli Bellek (LSTM) yöntemi aracılığıyla Sivas ili sınırlarında bulunan bir meteorolojik istasyondan elde edilen veriler kullanılarak günlük ortalama aylık güneş ışınımı verileri tahmin edilmiştir. Günlük ortalama aylık güneş ışınım verilerinin tahmininde zaman serisi yaklaşımı kullanılmıştır. Önerilen yöntem, karmaşık hesaplamalar gerektirmeden veya kapsamlı çevresel, topografik ve meteorolojik verilere sahip olmadan, günlük ortalama aylık güneş ışınım verilerinin bir ay ilerisini tahmin etmektedir. Zaman serisi yaklaşımı, zaman serisi verilerinin stokastik bileşenini yakalayabilir, ayrıca makine öğrenme araçları, zaman serisi verilerinin belirleyici kısmını tahmin edebilir. Bu nedenle bu çalışmada, günlük ortalama aylık güneş ışınım verilerinin zaman serisi verileri için makine öğrenmesi ve zaman serisi yöntemlerinin birlikte kullanıldığı bir tahmin yöntemi ele alınmıştır.

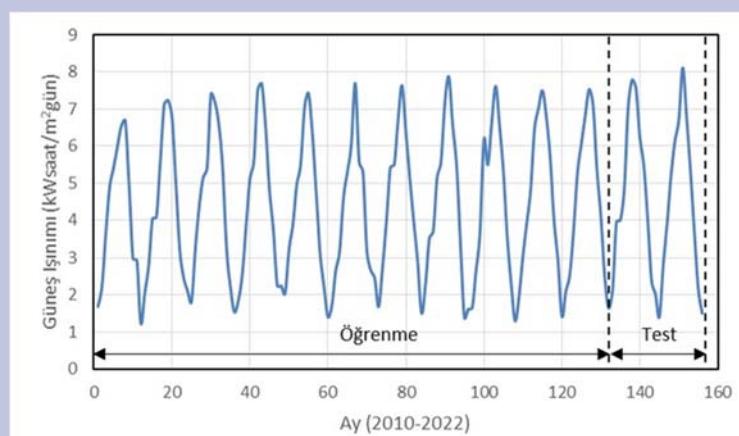
Yöntem

Çalışma Alanı ve Veri

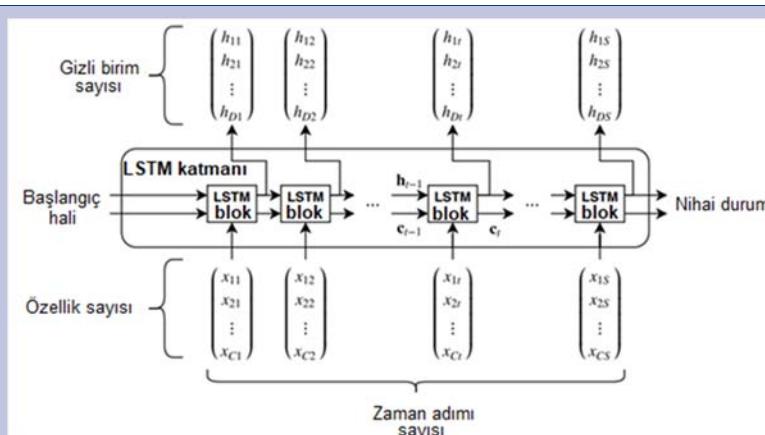
Bu çalışmada, Meteoroloji Genel Müdürlüğü'nün Sivas il sınırları içerisinde bulunan bir ölçüm istasyonundan elde edilen üç yıllık (2010-2022) günlük ortalama aylık toplam güneş ışınımı verileri kullanılmıştır. Rakımı 1121 m olan ölçüm istasyonunun konum haritası Şekil 1'de sunulmuştur. Konum haritası ArcGIS Pro yazılımı kullanılarak oluşturulmuştur.



Şekil 1. Ölçüm istasyonunun konum haritası
Figure 1. Location map of the measuring station



Şekil 2. Aylık toplam güneş ışınımı dağılımı
Figure 2. Distribution of the monthly global solar radiation



Şekil 3. LSTM katman mimarisi
Figure 3. LSTM layer architecture

Ölçüm istasyonunun 2010-2022 yılları arasındaki aylık ortalama toplam güneş ışınımı, minimum sıcaklık, maksimum sıcaklık, ortalama sıcaklık, bağıl nem ve yağış miktarı sırasıyla: 4,44 kWsaat/ $\text{m}^2/\text{gün}$, 0,20 $^{\circ}\text{C}$, 25,42 $^{\circ}\text{C}$, 12,53 $^{\circ}\text{C}$, %53,29 ve 28,42 mm dir. Şekil 2'de 2010-2022 yılları arasındaki aylık toplam güneş ışınımı dağılımı görülmektedir. LSTM analizlerinde 2010-2020 yılları arasındaki veriler eğitim için, 2021 ve 2022 yıllarına ait veriler ise test için kullanılmıştır.

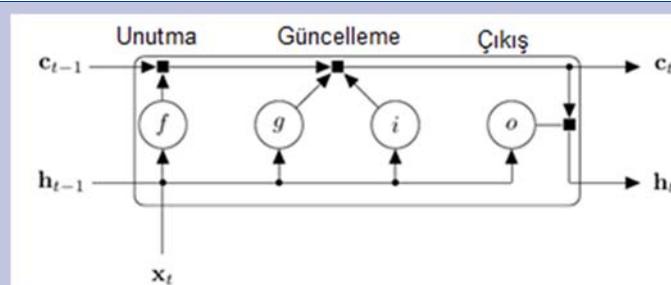
Uzun-Kısa Süreli Bellek Yöntemi

LSTM ağları zaman serilerinin tahmini için yaygın olarak kullanılan oldukça güçlü ve etkili bir tür geliştirilmiş tekrarlayan sinir ağı (RNN) yapılarıdır. LSTM ilk önce Hochreiter ve Schmidhuber (1997) tarafından ortaya konmuş daha sonra Gers ve ark. (2000) tarafından geliştirilmiştir. Genel olarak bir LSTM birimi (veya katmanı); bir hafıza hücresi (memory cell), bir giriş kapısı (input gate), bir çıkış kapısı (output gate) ve bir unutma kapısından (forget gate) oluşur. Giriş ve çıkış kapıları sırasıyla birime giren ve birinden verileri düzenler. Unutma kapısının en önemli görevi ise bir önceki zaman adımlına ait hangi verilerinin saklanacağına veya atılacağına (unutulacağına) karar vermektedir. Hafıza

hücresi ise bilginin kullanılabilir (yararlı) olup olmadığını değerlendirdir (Yu ve ark., 2019).

Tipik bir LSTM katman mimarisi Şekil 3'te sunulmuştur. Bu diyagram, S uzunluğundaki C özelliklerine sahip X zaman serisinin bir LSTM katmanından akışını göstermektedir. Diyagramda, h_t ve c_t sırasıyla çıkış (gizli durum olarak da bilinir) ve t zaman adımdındaki hücre durumunu gösterir.

İlk LSTM bloğu, ilk çıkışı ve güncellenmiş hücre durumunu hesaplamak için ağır başlangıç durumunu ve dizinin ilk zaman adımını kullanır. t zaman adımda blok, çıktıtı ve güncellenmiş hücre durumunu c_t hesaplamak için ağır mevcut durumunu (c_{t-1}, h_{t-1}) ve dizinin bir sonraki zaman adımını kullanır. Katmanın durumu, gizli durumdan (aynı zamanda çıkış durumu olarak da bilinir) ve hücre durumundan oluşur. t zaman adımdaki gizli durum, bu zaman adımı için LSTM katmanın çıkışını içerir. Hücre durumu, önceki zaman adımlarından öğrenilen bilgileri içerir. Her zaman adımda, katman hücre durumuna bilgi ekler veya hücre durumundan bilgi çıkarır. Katman, kapıları kullanarak bu güncellemeleri kontrol eder. Tablo 1, LSTM katman mimarisindeki bileşenleri ve bunların amaçlarını vermektedir. Bu bileşenler, katmanın hücre durumunu ve gizli durumunu kontrol eder.



Şekil 4. t zaman adımındaki veri akışı
Figure 4. Data flow at time step t

Tablo 1. LSTM katman mimarisindeki bileşenler ve amaçları

Table 1. LSTM architecture components and their purposes

Bileşen	Amaç
Giriş geçidi (i)	Hücre durumu güncellemesinin düzeyini kontrol eder
Unutma geçidi (f)	Hücre durumu sıfırlamasının düzeyini kontrol eder
Hücre geçidi (g)	Hücre durumuna bilgi ekler
Çıkış geçidi (o)	Gizli duruma eklenen hücre durumunun düzeyini kontrol eder

Tablo 2. t zaman adımındaki bileşenleri açıklayan formüller

Table 2. Formulas describing the components at time step t

Bileşen	Eşitlik
Giriş geçidi (i)	$i_t = \sigma_g(W_i x_t + R_i h_{t-1} + b_i)$ (4)
Unutma geçidi (f)	$f_t = \sigma_g(W_f x_t + R_f h_{t-1} + b_f)$ (5)
Hücre geçidi (g)	$g_t = \sigma_c(W_g x_t + R_g h_{t-1} + b_g)$ (6)
Çıkış geçidi (o)	$o_t = \sigma_g(W_o x_t + R_o h_{t-1} + b_o)$ (7)

Şekil 4, t zaman adımındaki veri akışını göstermektedir.

Bu diyagram, kapıların hücreyi ve gizli durumları nasıl unuttuğunu, güncellediğini ve çıktısını vurgular.

Bir LSTM katmanın öğrenilebilir ağırlıkları, girdi ağırlıkları W , yinelenen ağırlıklar R ve bias b dir. W , R ve b matrisleri, sırasıyla her bir bileşenin girdi ağırlıklarının, yinelenen ağırlıklarının ve biasın birleşimidir. Bu matrisler aşağıdaki gibi birleştirilir:

$$W = \begin{bmatrix} W_i \\ W_f \\ W_g \\ W_o \end{bmatrix}, R = \begin{bmatrix} R_i \\ R_f \\ R_g \\ R_o \end{bmatrix}, b = \begin{bmatrix} b_i \\ b_f \\ b_g \\ b_o \end{bmatrix} \quad (1)$$

Burada i , f , g ve o sırasıyla giriş geçidini, unutma geçidini, hücre adayını ve çıkış geçidini gösterir. t zaman adımındaki hücre durumu aşağıdaki şekilde verilir:

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (2)$$

Burada \odot , vektörlerin eleman bazında çarpımını belirtir. t zaman adımındaki gizli durum şu şekilde verilir:

$$h_t = o_t \odot \sigma_c(c_t) \quad (3)$$

Burada σ_c durum aktivasyon fonksiyonunu gösterir. LSTM işlevi, durum etkinleştirme işlevini hesaplamak için varsayılan olarak hiperbolik tanjant işlevini ($tanh$) kullanır. Tablo 2, t zaman adımındaki bileşenleri açıklayan formüllerini vermektedir.

Bu hesaplamlarda σ_g geçit aktivasyon fonksiyonunu ifade eder. LSTM işlevi, varsayılan olarak, geçit aktivasyon fonksiyonunu hesaplamak için aşağıdaki gibi ifade edilen sigmoid işlevini kullanır. Detaylı matematiksel arka plan Hochreiter ve Schmidhuber (1997), ve Bilgili ve ark., (2022) çalışmalarında bulunabilir.

$$\sigma(x) = (1 + e^{-x})^{-1} \quad (8)$$

Istatistiksel Test Yöntemleri

LSTM modelinin tahmin başarısını sınamak için aşağıda formülleri verilen üç farklı istatistiksel değerlendirme ölçüyü: ortalama mutlak yüzde hata (MAPE), kök ortalama kare hatalı (RMSE) ve korelasyon katsayısı (R) kullanılmıştır. MAPE ve RMSE değerlerinin olabildiğince küçük ve sıfır yakını olması istenir. MAPE değerleri için; $MAPE \leq 10\%$ yüksek tahmin doğruluğunu, $10\% \leq MAPE \leq 20\%$ iyi tahmini, $20\% \leq MAPE \leq 50\%$ kabul edilebilir tahmini ve $MAPE \geq 50\%$ hatalı tahmini göstermektedir (Rao ve ark., 2018).

Ortalama mutlak yüzde hata (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{O}_i - T_i}{\hat{O}_i} \right| \times 100 \quad (9)$$

Kök ortalama kare hatalı (RMSE):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{O}_i - T_i)^2}{n}} \quad (10)$$

Korelasyon katsayısı (R):

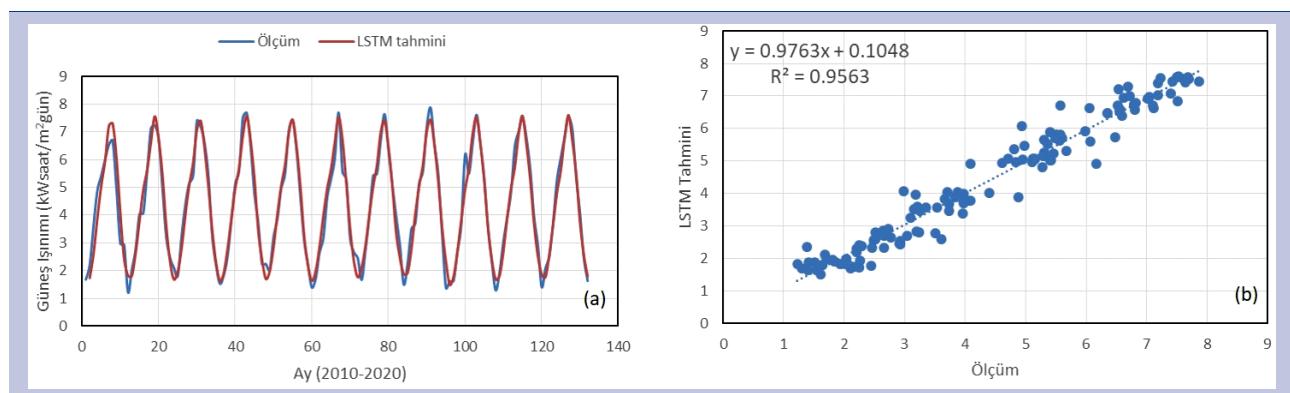
$$R = \frac{\sum(\ddot{O}_i - \bar{\ddot{O}})(T_i - \bar{T})}{\sqrt{\sum(\ddot{O}_i - \bar{\ddot{O}})^2 (T_i - T)^2}} \quad (11)$$

Bulgular ve Tartışma

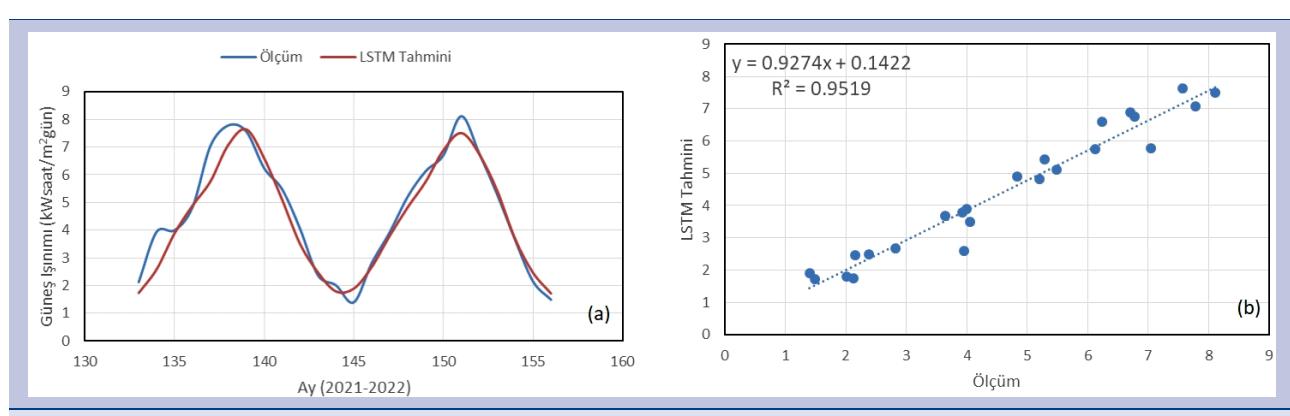
Bu çalışmada aylık toplam güneş ışınımı tahmini için LSTM yöntemi kullanılarak zaman serisi analizi yapılmıştır.

Bu yöntemin en önemli avantajı güneş ışınımı tahmini için; güneşlenme süresi, sıcaklık, nem, bulutluluk, yağış miktarı gibi diğer meteorolojik verilere ihtiyaç duymamasıdır. LSTM ağının eğitimi ve tahminleri için geçmiş yillarda ait aylık güneş ışınımı verileri girdi olarak kullanılmıştır.

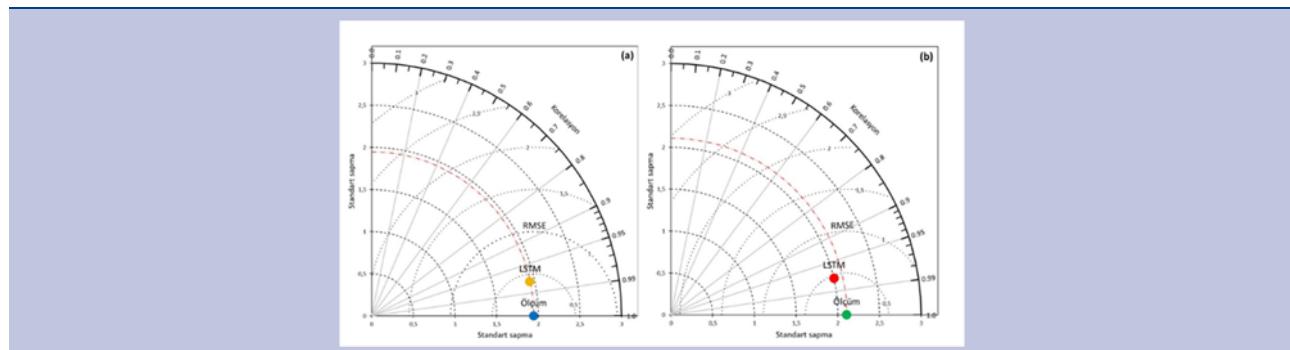
LSTM yöntemiyle elde edilen ölçüm ve tahmin değerlerinin dağılımı ve regresyon analiz grafikleri eğitim ve test için sırasıyla Şekil 5 ve Şekil 6'da sunulmuştur. Şekil 5 ve 6'dan LSTM ağının oldukça iyi eğitildiği, 2021-2022 yıllarındaki test döneminde tahmin verilerinin ölçüm verilerini iyi bir şekilde temsil ettiği açıkça görülmektedir. Bununla birlikte test döneminde ölçüm verilerinin daha az tahmin edilme (underestimate) eğiliminde olduğu dikkat çekmektedir.



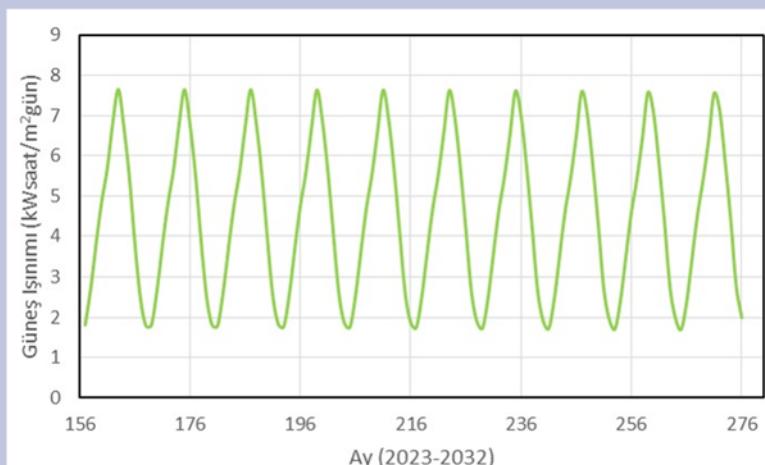
Şekil 5. Eğitim için a) aylık toplam güneş ışınımı ölçüm ve tahmin dağılımı, b) korelasyon grafiği
Figure 5. For training a) distributions of the measured and predicted monthly global solar radiation, b) correlation graph



Şekil 6. Test için a) aylık toplam güneş ışınımı ölçüm ve tahmin dağılımı, b) korelasyon grafiği
Figure 6. For testing a) distributions of the measured and predicted monthly global solar radiation, b) correlation graph



Şekil 7. Taylor diyagramı a) eğitim b) test
Figure 7. Taylor diagram a) train b) test



Şekil 8. Önümüzdeki on yıl için aylık toplam güneş ışınımı dağılımı
Figure 8. Distribution of the monthly global solar radiation for the next ten years

Eğitim verileri için istatistiksel değerlendirme ölçütleri; MAPE, RMSE ve R değerleri sırasıyla %9,129, 0,407 ve 0,978 olarak elde edilmiştir. Test verileri için MAPE, RMSE ve R değerleri sırasıyla %9,446, 0,496 ve 0,976 olarak elde edilmiştir. Hem eğitim hem de test verileri için MAPE değerlerinin 10'dan küçük olduğu görülmektedir. Elde edilen istatistiksel tahmin değerlendirme ölçütlerine göre LSTM'nin ilgili istasyon için aylık toplam güneş ışınımını yüksek doğrulukta tahmin ettiği görülmektedir. Ek olarak bu bulgular; standart sapma, korelasyon katsayısı ve kök ortalama kare hatasını aynı anda gösteren Taylor diyagramı (Taylor, 2001) aracılığıyla da doğrulanabilir. Şekil 7'de Taylor diyagramı sunulmuştur. Şekil 8'de ileriye dönük 10 yıllık toplam güneş ışınımı tahminlerine ait dağılım sunulmuştur.

Sonuç

Bu çalışmada Uzun-Kısa Süreli Bellek (LSTM) yöntemi aracılığıyla günlük ortalama aylık güneş ışınımı için ileriye dönük tahminler yapılmıştır. Tahminler için Sivas il sınırları içerisinde bulunan bir ölçüm istasyonundan elde edilen on üç yıllık (2010-2022) güneş ışınımı verileri kullanılmıştır. 2010-2020 yılları arasındaki 132 aylık veri eğitim için, 2021 ve 2022 yıllarına ait 24 aylık veri ise test için kullanılmıştır. Tahminlerin doğruluğu MAPE, RMSE ve R istatistiksel değerlendirme ölçekleriyle sınanmıştır. Eğitim ve test için sırasıyla MAPE değeri %9,129 ve %9,446, RMSE değeri 0,407 ve 0,496, R değeri ise 0,978 ve 0,976 olarak elde edilmiştir. LSTM'nin günlük ortalama aylık toplam güneş ışınımını yüksek doğrulukta tahmin ettiği görülmüştür. LSTM yönteminin incelenen bölgede daha önceki güneş ışınımı verileri kullanılarak ileriye dönük güneş ışınımı tahminlerinde etkin olarak kullanılabileceği sonucuna varılmıştır.

Teşekkür

Verileri sağlayan Meteoroloji Genel Müdürlüğü'ne teşekkür ederiz.

Referanslar

1. Akinoğlu, B. G. & Ecevit, A. (1990). Construction of a Quadratic Model Using Modified Angstrom Coefficients to Estimate Global Solar Radiation. *Solar Energy*, 45 (2), 85–92. [https://doi.org/10.1016/0038-092X\(90\)90032-8](https://doi.org/10.1016/0038-092X(90)90032-8)
2. Arslan, G., Bayhan, B. & Yaman, K. (2019). 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. <https://doi.org/10.29109/gujsc.419473>
3. Bakırıcı, K. (2009). Correlations for Estimation of Daily Global Solar Radiation with Hours of Bright Sunshine in Turkey. *Energy*, 34 (4), 485–501. <https://doi.org/10.1016/j.energy.2009.02.005>
4. Ballı, Ö. (2021). Estimating Global Solar Radiation from Empirical Models: An Application. *European Mechanical Science*, 5 (3), 135-147. <https://doi.org/10.26701/ems.797177>
5. Bilgili, M. & Ozgoren, M. (2011). Daily Total Global Solar Radiation Modeling from Several Meteorological Data. *Meteorology and Atmospheric Physics*, 112, 125-138. <https://doi.org/10.1007/s00703-011-0137-9>
6. Bilgili, M., Arslan, N., Şekertekin, A. & Yaşar, A. (2022). Application of Long Short-Term Memory (LSTM) Neural Network Based on Deeplearning for Electricity Energy Consumption Forecasting. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30 (1), 140-157. <https://doi.org/10.3906/elk-2011-14>
7. BP. (2022). Statistical Review of World Energy.
8. Celik, A. N. & Muneer, T. (2013). Neural Network Based Method for Conversion of Solar Radiation Data. *Energy Conversion and Management*, 67, 117–124. <https://doi.org/10.1016/j.enconman.2012.11.010>
9. Gers, F. A., Schmidhuber, J. & Cummins, F. (2000). Learning to Forget: Continual Prediction with LSTM. *Neural Computation*,

- 12 (10), 2451-2471.
<https://doi.org/10.1162/089976600300015015>
10. Gurlek, C. & Sahin, M. (2018). Estimation of the Global Solar Radiation with the Artificial Neural Networks for the City of Sivas. European Mechanical Science, 2 (2), 46-51.
<https://doi.org/10.26701/ems.359681>
11. GüL, M. & Çelik, E. (2017). ANFIS Kullanılarak Tunceli İli için Global Güneş Radyasyonu Tahmini. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 8 (4), 891-899.
12. Hochreiter, S. & Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation, 9 (8), 1735–1780.
<https://doi.org/10.1162/neco.1997.9.8.1735>
13. Koca, A., Oztop, H. F., Varol, Y. & Koca, G. O. (2011). Estimation of Solar Radiation Using Artificial Neural Networks with Different Input Parameters for Mediterranean Region of Anatolia in Turkey. Expert Systems with Applications, 38 (7), 8756–8762. <https://doi.org/10.1016/j.eswa.2011.01.085>
14. Ozgoren, M., Bilgili, M. & Sahin, B. (2012). Estimation of Global Solar Radiation using ANN over Turkey. Expert Systems with Applications, 39 (5), 5043-5051.
<https://doi.org/10.1016/j.eswa.2011.11.036>
15. Rao, K. D. V. S. K., Premalatha, M. & Naveen, C. (2018). Analysis of Different Combinations of Meteorological Parameters in Predicting the Horizontal Global Solar Radiation with ANN Approach: A Case Study. Renewable and Sustainable Energy Reviews, 91, 248–58.
<https://doi.org/10.1016/j.rser.2018.03.096>
16. Sahin, M., Kaya, Y. & Uyar, M. (2013). Comparison of ANN and MLR Models for Estimating Solar Radiation in Turkey using NOAA/AVHRR Data. Advances in Space Research, 51 (5), 891-904. <https://doi.org/10.1016/j.asr.2012.10.010>
17. Sen, Z., Oztopal, A. & Sahin, A. D. (2004). Solar Irradiation Estimation from Sunshine Duration by Geno-Fuzzy Partial Approach. Energy Sources, 26, 377–386.
<https://doi.org/10.1080/00908310490266814>
18. Sözen, A., Arcaklıoglu, E. & Özalp, M. (2004). Estimation of Solar Potential in Turkey by Artificial Neural Networks Using Meteorological and Geographical Data. Energy Conversion and Management, 45 (18-19), 3033–3052.
<https://doi.org/10.1016/j.enconman.2003.12.020>
19. Sözen, A. & Arcaklıoglu, E. (2005). Solar Potential in Turkey. Applied Energy, 80 (1), 35–45.
<https://doi.org/10.1016/j.apenergy.2004.02.003>
20. Şenkal, O. & Kuleli, T. (2009). Estimation of Solar Radiation Over Turkey Using Artificial Neural Network and Satellite Data. Applied Energy, 86 (7-8), 1222–1228.
<https://doi.org/10.1016/j.apenergy.2008.06.003>
21. Şenkal, O. (2010). Modeling of Solar Radiation Using Remote Sensing and Artificial Neural Network in Turkey. Energy, 35 (12), 4795–4801.
<https://doi.org/10.1016/j.energy.2010.09.009>
22. Taylor, K. E. (2001). Summarizing Multiple Aspects of Model Performance in a Single Diagram, Journal of Geophysical Research Atmospheres, 106 (D7), 7183-7192.
<https://doi.org/10.1029/2000JD900719>
23. Yıldız, B. Y., Şahin, M., Şenkal, O., Pestemalcı, V. & Emrahoglu, N. (2013). A Comparison of two Solar Radiation Models Using Artificial Neural Networks and Remote Sensing in Turkey. Energy Sources, Part A, 35 (3), 209–217.
<https://doi.org/10.1080/15567036.2011.650276>
24. Yu, J., Ding, F., Guo, C. & Wang, Y. (2019). System Load Trend Prediction Method Based on IF-EMD-LSTM. International Journal of Distributed Sensor Networks, 15 (8).
<https://doi.org/10.1177/1550147719867655>
25. Zhang, J., Zhao, L., Deng, S., Xu, W. & Zhang, Y. (2017). A Critical Review of the Models Used to Estimate Solar Radiation. Renewable and Sustainable Energy Reviews, 70, 314–329.
<http://dx.doi.org/10.1016/j.rser.2016.11.124>