

Global Solar Irradiance Time Series Prediction Using Long Short-Term Memory Network

Ahmet KARA 

Hitit University, Faculty of Engineering, Department of Industrial Engineering, 19030, Merkez/ÇORUM

Graphical/Tabular Abstract

In this study, it is proposed a deep neural network approach, which has the capability to extract superior features on complex and nonlinear time series data, for forecasting global solar irradiance more accurately. This approach has also been used to expose both the relationship between input data and output data, as well as the contribution of input data to the output data.

Article Info:

Research article

Received: 30/05/2019

Revision 10/10/2019

Accepted: 20/10/2019

Highlights

- LSTM model for the global solar irradiance prediction.
- Comparison with state-of-the-art approaches.
- Considering the performance criteria consisting of MAE, RMSE, MAPE, and r2.

Keywords

Deep neural network
 Time series forecasting
 Long short-term memory
 Solar irradiance
 Machine learning




Figure A. The box plot of solar irradiance (a) Year (b) Quarter.

Purpose: In this study, it is aimed to develop an accurate and effective prediction model using the LSTM neural network due to a rapidly growing interest in solar power generation. It is aimed to reveal that the proposed model based on a deep learning approach outperforms compared to machine learning models and statistical models.

Theory and Methods: To overcome the complexity and nonlinearity issues in time series forecasting, the LSTM neural network that is a variation of the recurrent neural network is used to predict daily global solar irradiance. The effectiveness of the suggested method is compared with the state of the art machine learning algorithms such as Decision Tree Regression, Random Forest Regression, Gradient Boosting, and K-Nearest Neighbor.

Results: To evaluate the performance of the proposed model for daily global solar irradiance, it is compared by four metrics comprising MAE, RMSE, MAPE, and r2. The results have shown that the proposed LSTM model is more effective and superior according to the other benchmark models.

Conclusion: In this study, it has been suggested a deep LSTM model based on deep learning for forecasting daily global solar irradiance more accurately. The presented LSTM model can extract quality features that represent sophisticated and nonlinear characteristics of time series data. Also, it has been indicated that the proposed model is a robust and useful model compared with state-of-the-art machine learning models.



Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini

Ahmet KARA 

Hitit Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, ORCID:0000-0002-1590-0023, 19030, Merkez/ÇORUM

Makale Bilgisi

Araştırma makalesi
Başvuru: 30/05/2019
Düzeltilme: 10/10/2019
Kabul: 20/10/2019

Anahtar Kelimeler

Derin sinir ağı
Zaman serileri tahmini
Uzun kısa süreli hafıza
Güneş ışınımı
Makine öğrenmesi

Keywords

Deep neural network
Time series forecasting
Long short-term memory
Solar irradiance
Machine learning

Öz

Global güneş ışınımı tahmini, güneş enerjisi sistemlerinin etkin yönetimi ve işletilmesinin yanı sıra gelecekteki enerji üretimi hakkında güvenilir bilgi sağlamak için giderek daha fazla önem kazanmaktadır. Bu çalışmada, günlük güneş ışınım tahmin problemini etkin bir model oluşturmak için Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ağı önerilmiştir. Önerilen yöntemin etkinliği Karar Ağaçları Regresyon, Rastgele Orman Regresyon, Gradyan Güçlendirme ve K-En Yakın Komşu gibi en etkili makine öğrenme algoritmaları ile karşılaştırılmıştır. LSTM modelinin yaklaşımının etkinliğini doğrulamak için Çorum - Türkiye'de Temmuz-1983 ve Aralık-2018 tarihleri arasında global güneş ışınımı sıralı zaman serileri verileri kullanılmıştır. Simülasyon sonuçları, LSTM yönteminin diğer makine öğrenme modellerinden daha iyi performansa sahip olduğunu göstermektedir.

Global Solar Irradiance Time Series Prediction Using Long Short-Term Memory Network

Abstract

Global solar radiation estimation is increasingly acquiring more importance to ensure effective management and operation of solar energy systems as well as providing reliable information about the future power generation. In this study, the Long Short-Term Memory (LSTM) has been suggested to effectively model the daily solar radiation prediction problem. The effectiveness of the suggested method compared with the state of the art machine learning algorithms such as Decision Tree Regression, Random Forest Regression, Gradient Boosting and K-Nearest Neighbor. Daily solar irradiance sequential time series data in Çorum - Turkey between January-1983 and December-2018 have been used to validate the effectiveness of the suggested LSTM method. The simulation outcomes demonstrate that LSTM method has generally better performance than the other machine learning models.

1. GİRİŞ (INTRODUCTION)

Günümüzde insanlar tarafından kullanımı her geçen gün artan petrol ürünleri, doğalgaz ve kömür gibi fosil yakıtların, dünya üzerinde ozon tabakasının delinmesi, küresel ısınma, havanın kirlenmesi sonucunda meydana gelen asit yağmurları ve çevre kirliliği gibi etkileri dünya üzerinde telafisi mümkün olmayan sonuçlara neden olmaktadır [1].

Fosil yakıtların kullanımından kaynaklanan çevresel sorunlar, sürekli artan enerji talebi ve insan sağlığı üzerindeki olumsuz etkilerinden dolayı yenilenebilir enerji kaynaklarına yapılan yatırımları arttırmaktadır. Yenilenebilir enerji kaynakları arasında en yaygın olarak kullanılanlar arasında güneş enerjisi gelmektedir. Güneş enerjisi, tükenmeyen ve çevreyi kirletmeyen doğal bir enerji kaynağı olması nedeniyle yaşamın sürdüğü tüm alanlarda kullanılabilir. Güneş enerjisi uygulamalarının ve sistemlerinin fizibilite çalışmaları için, sağlıklı ve kolay ulaşılabilir olmasından dolayı güneş ışınım değerlerinin tahmini gerekmektedir [2]. Bu çalışmada, dünya yüzeyine düşen günlük güneş ışınım değerlerinin tahmini için son

yıllarda araştırmacılar tarafından sıklıkla kullanılan Derin öğrenme yaklaşımlarından LSTM yöntemi uygulanmıştır.

Yapay zekâ alanında son yıllarda üzerinde durulan yeni bir makine öğrenme yöntemi olan derin öğrenme, büyük miktarda verilerden etkili özellik temsillerinin öğrenilmesine katkı sağlayan etkin algoritmalar sunmaktadır [3]. Derin öğrenme modelleri, özellikle hisse senedi fiyat tahmini, hava kirliliği tahmini ve enerji fiyatları tahmini gibi zaman serileri tahmini problemlerinde yoğun bir şekilde kullanılmaktadır. Zaman serisi tahmin sistemleri, geçmiş ve şimdiki durum bilgilerine dayanarak gelecekteki davranışları öngörmeye dayanır. Geçmişte, zaman serileri problemlerinin çözümü için lineer istatistiksel yöntemler sunulurdu. Günümüzde ise veri boyutunun artmasıyla karmaşık ve lineer olmayan zaman serileri tahminleri için lineer istatistiksel yöntemler yetersiz kalmaktadır [4]. Ayrıca zaman serisi verilerinden manuel olarak etkin özelliklerin belirlenmesinin zor olmasından dolayı, verilerdeki karmaşıklık ve lineer olmayan ilişkileri öğrenme kabiliyetine sahip Derin yapay sinir ağları önerilmiştir. Derin sinir ağları algoritmaları arasında LSTM, zaman serileri tahmininde geniş çapta kullanılmaktadır.

LSTM, tekrarlayan sinir ağları mimarisinin özel bir türü olarak Hochreiter ve Schmidhuber [5] tarafında geliştirilmiştir. LSTM algoritması, zaman serileri verilerinden otomatik özellik çıkarma yeteneği ve karmaşık lineer olmayan durumları öğrenmesi ile dikkat çekmektedir.

Bu çalışmada, doğrusal olmayan ve karmaşık güneş ışıınımı verilerinin tahmini için derin LSTM mimarisi önerilmiştir. Güneş ışıınımı değerlerinin tahmini için Çorum ilinin Temmuz-1983 ve Aralık-2018 tarihleri arasındaki sıralı zaman serisi verileri kullanılmıştır. Önerilen derin öğrenme yaklaşımı, orijinal Tekrarlayan sinir ağları (Recurrent neural network - RNN) modelinin bir uzantısıdır; burada, her bir katman birden fazla nöron içerecek şekilde çoklu LSTM katmanları içerir. Ayrıca LSTM modelinin sonuçlarının doğruluğunu ve etkinliğini değerlendirmek için makine öğrenmesi algoritmaları ile karşılaştırılmıştır.

2. İLGİLİ ÇALIŞMALAR (RELATED WORK)

Güneş ışıınının, güneş enerjisinin elde edilmesi ile doğru orantılı olması ve güneş enerjisi üretiminde dikkate alınacak bir parametre olması nedeniyle literatürde güneş ışıınımı tahmini yoğun olarak incelenmiştir. Tahmin yöntemleri kabaca üç kategoriye ayrılabilir: fiziksel, istatistiksel ve makine öğrenmesi yöntemleri [6]. Fiziksel yöntemde, tahmin, uzun bir tahmin periyotları (1 ve 2 gün) için daha uygun olan sayısal hava tahmin modelleri ile uygulanır. İstatistiksel yöntemler ise geçmiş zaman serileri verilerine dayanır. Yapay zeka algoritmasının bir alt dalı olan makine öğrenmesi, girdi-çıkı verileri arasındaki lineer olmayan ilişkiyi verilerden öğrenir. Bu çalışmada, güneş ışıınım değerlerinin tahmini için derin öğrenme yaklaşımı uygulanacaktır ve bu yaklaşım makine öğrenmesi algoritmaları ile karşılaştırılacaktır.


Güneş ışıınım tahmin problemi için literatürde; meta-sezgisel algoritmalar, bulanık mantık ve yapay sinir ağları ve karma (hybrid) sistemler gibi yapay zekâ ve istatistiksel yöntemler kullanılmıştır [7-10]. Pedro vd. [11] tarafından yapılan bir çalışmada güneş enerjisi tahmininde farklı makine öğrenmesi yaklaşımlarının performansları değerlendirilmiştir. Arslan vd. tarafından Mersin ilinin güneş ışıınım değerlerini yapay sinir ağı kullanılarak tahmin etmişlerdir [12]. Ayrıca güneş ışıınım değerlerinin tahmininde; Destek Vektör Makinası (Support Vector Machines - SVM), Rastgele Orman Regresyon (Random Forest Regression - RFR), K-Nearest Neighbor Regresyon (kNN Regression - KNN), Aşırı Öğrenme Makinesi (Extreme Learning Machine - ELM) gibi birçok makine öğrenmesi algoritması kullanılmıştır [9, 13, 14].

Zaman serisi problemlerinin analizlerinde, son yıllarda araştırmacılar tarafından tercih edilen LSTM yöntemi kompleks ve lineer olmayan verilerin tahmin tutarlılığında ciddi iyileştirmeler sağlamıştır. Sagheer ve Kotb [4] yaptıkları çalışmada petrol fiyatlarının tahmini için LSTM algoritmasını kullanmışlardır. Bouktif vd. ise LSTM parametre optimizasyonu için genetik algoritma yaklaşımı sunmuştur [15]. Bunların yanında finans piyasalarında hisse senetlerinin fiyat tahminleri LSTM algoritmasının performansı incelenmiştir [16, 17]. Son yıllarda literatürde, hava kirliliği tahmini, su kalitesinin tahmini ve ozon gazları yoğunluğunun tahmini gibi çevresel zaman serisi problemlerinde tahmin doğruluğunun yüksekliğinden dolayı LSTM yaklaşımı tercih edilmiştir [3, 18]. Qing ve Niu [19] yaptıkları çalışmada, saatlik güneş ışıınımı değerlerinin tahmini LSTM yöntemi kullanmışlar ve girdi verileri olarak aynı zaman dilimine ait hava tahmin değerleri kullanılmıştır. Alzahrani vd. [20] ise güneş ışıınım değerlerinin tahmini için derin

sinir ağırları kullanmışlardır. Bu çalışmada ise Çorum ilinin güneş ışınım değerlerinin derin sinir ağı yaklaşımı olan RNN mimarisinin özel bir türü olan LSTM algoritması kullanılmıştır. Ayrıca LSTM algoritmasına girdi verisi olarak geçmiş güneş ışınım değerlerinin farklı zaman periyodları kullanılmıştır.

3. UZUN KISA SÜRELİ BELLEK (LONG-SHORT TERM MEMORY)

Uzun kısa süreli bellek, sıralı verilerin modellenmesi için uygulanan RNN yaklaşımının özel bir türü olarak 1990 yılların sonunda geliştirilmiştir. RNN yaklaşımında genel olarak, girdi verisindeki her bir bilgi bir önceki çıktının değerini de dikkate alarak tekrarlı olarak inceler. Bu mimaride önceki zaman dilimindeki bilgileri göz önüne alan bir öğrenme gerçekleştirdiği iddia edilmesine rağmen gradyan kaybolması/patlaması sorunu sebebi ile bunun mümkün olmadığı belirtilmiştir [5, 21]. Bu sorunun üstesinden gelmek için uzun süreli bilgiyi hatırlayabilen LSTM mimarisi geliştirilmiştir.



Şekil 1. Uzun kısa süreli hafıza mimari yapısı [22].

LSTM mimarisi, Şekil 1'de gösterildiği gibi birbirini tekrar eden sıralı bloklardan oluşur. Genel olarak LSTM yapısında unut, girdi ve çıktı olmak üzere 3 farklı katmandan oluşur. LSTM mimarisinde öncelikle girdi olarak X_t ve h_{t-1} bilgileri kullanılarak hangi bilgilerin silineceğine karar verilir. Bu işlemler unut katmanında (f_t) Eşitlik (1) kullanılarak yapılır ve aktivasyon fonksiyonu olarak sigmoid kullanılır.

$$f_t = \sigma(W_{f,x} * X_t + W_{f,h} * h_{t-1} + b_f) \quad 1$$

İkinci adımda yeni bilgilerin belirleneceği girdi katmanı devreye girer ve öncelikle (i_t) Eşitlik (2) kullanılarak *sigmoid* fonksiyonu ile bilgiler güncellenir. Ardından Eşitlik (3) ile yeni bilgiyi oluşturacak aday bilgiler *tanh* fonksiyonu tarafından belirlenir.

$$i_t = \sigma(W_{i,x} * X_t + W_{i,h} * h_{t-1} + b_i) \quad 2$$

$$\tilde{C}_t = \tanh(W_{c,x} * X_t + W_{c,h} * h_{t-1} + b_c) \quad 3$$

Eşitlik (4) tarafından yeni bilgiler oluşturulur.

$$C_t = C_{t-1} * f_t + i_t * \tilde{C}_t \quad 4$$

Son olarak çıktı katmanında Eşitlik (5) ve (6) kullanılarak çıktı verileri elde edilir.

$$o_t = \sigma(W_{o,x} * X_t + W_{o,h} * h_{t-1} + b_o) \quad 5$$


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

Yukarıda ifade edilen süreç tekrarlanarak devam eder. Ağırlık parametreleri (W) ve bias parametreleri (b) gerçek eğitim değerleri ile LSTM çıktı değerleri arasındaki farkı minimize edecek şekilde model tarafından öğrenilmektedir [4, 17, 23].

4. VERİ VE DENEYSEL ÇALIŞMALAR (DATA AND EXPERIMENTAL STUDIES)


4.1. Veri Tanımı (Data Description)

Bu bölümde, güneş ışınımı değerlerinin LSTM yöntemi ile tahmininde kullanılacak veri kümesinden, verilerin hazırlanması sürecinden, LSTM yönteminden elde edilen sonuçlarının doğruluğunun testi için karşılaştırma yapılacak makine öğrenmesi algoritmalarından ve son olarak eğitim verisi ile test verilerinin oluşturulmasından bahsedilecektir.



Şekil 2. Çorum ili güneş ışınım değerleri (2010-2018)

Bu çalışmada, Çorum ilinin Temmuz-1983 ve Aralık-2018 tarihleri arasındaki günlük güneş ışınım değerleri kullanılmıştır. Bu veriler Amerika'nın Ulusal Havacılık ve Uzay Dairesi (NASA) tarafından yayınlanan POWER (Prediction Of Worldwide Energy Resource) proje veri setinden elde edilmiştir (<https://power.larc.nasa.gov/>). Kullanılan veri seti 12969 adet kayıt içermektedir. Bu verilerin % 80'i eğitim verisi geriye kalan % 20'lik veri ise test verisi olarak değerlendirilmiştir. Çorum ilinin 2010-2018 tarihleri arasındaki güneş ışınım değerlerinin zamana bağlı grafiği Şekil 2'de sunulmuştur.



Şekil 3. Güneş ışınım kutu grafiği (a) Yıllık (b) Mevsimlik

Çorum ilinin güneş ışınım değerlerinin kutu grafikleri Şekil 3'de gösterilmiştir. Yıllara göre ortalama değerlerinin (Şekil 3a) neredeyse aynı olduğu görülmektedir. Fakat güneş ışınım değerlerini mevsimlere göre incelendiğinde (Şekil 3b) yaz aylarında daha yüksek olurken sonbahar ve kış aylarında daha düşük olduğu görülmektedir.

4.2. Karşılaştırma Modelleri ve Performans Ölçümleri (The Benchmark Models And Performance Measurements)

Güneş ışınımı değerlerinin tahmini için önerilen LSTM algoritmasından elde edilen sonuçların performansını ve doğruluğunu karşılaştırmak amacıyla literatürde var olan bazı makine öğrenmesi algoritmaları seçilmiştir. Seçilen makine öğrenmesi algoritmaları şunlardır; Rastgele Orman Regresyon (Random Forest Regression) [24], K-En Yakın Komşu (K-Nearest Neighbor) [25], Gradyan Güçlendirme (Gradient Boosting) [26] ve Karar Ağaçları Regresyon (Decision Tree Regression) [27]. Seçilen makine öğrenmesi algoritmalarının temel parametreleri Tablo 1’de gösterilmiştir. Bu parametreler Bouktif vd. [15] tarafından yapılan çalışmadan alınmıştır.

Tablo 1. Seçilen yöntemlerin parametre değerleri

No	Model	Parametreler
1	K-En Yakın Komşu	Komşu sayısı $n = 5$, ağırlık fonk. = uniform, mesafe ölçütü = Öklid
2	Rastgele Orman Regresyon	Ağaç sayısı = 125, ağacın max derinliği = 100, min samples split = 4, min sample leaf = 4
3	Gradyan Güçlendirme	Estimator sayısı = 125, max derinlik = 100, min samples split = 4, min sample leaf = 4
4	Karar Ağaçları Regresyon	Ağacın max derinliği = 100, min samples split = 4, min sample leaf = 4

Bu makalede kullanılan modellerde, kayıp fonksiyon olarak Ortalama Hata Kareleri (mean squared error - MSE) ölçütü tercih edilmiştir. Kayıp fonksiyon, modelin hata oranını diğer bir ifade ile başarı oranını ölçmektedir. Modellerin tahmin değeri ile gerçek değerler arasındaki farkı minimize edecek şekilde uygun model parametreleri belirlenir. Bu makalede kullanılan modellerde, kayıp fonksiyon olarak Ortalama Hata Kareleri (mean squared error - MSE) ölçütü tercih edilmiştir. MSE, gerçek değer ile tahmin değeri arasındaki ortalama kare farkıdır ve aşağıdaki Eşitlik (7) kullanılarak formülize edilir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (o_i - p_i)^2 \quad 7$$

Yukarıdaki eşitliklerde kullanılan N örnek sayısı, o_i i. gözlemin gerçek değeri, p_i i. gözlemin tahmin değeri ve \bar{o} ise gerçek gözlem değerlerinin ortalamasını ifade etmektedir. Bütün modellerde aynı eğitim ve test verileri kullanılmıştır.

Çorum ilinin günlük güneş ışınım değerlerinin tahmini için önerilen LSTM modelin mimarisi sırasıyla; bir tane girdi katmanı (input layer), 128 nörondan oluşan gizli katman (hidden layer), 0.2 oranında seyreltme (dropout) katmanı, 64 nörondan oluşan gizli katman (hidden layer), 0.2 oranında seyreltme (dropout) katmanı, aktivasyon fonksiyonu *relu* olan 16 nörondan oluşan dense katmanı ve son olarak 1 nörondan oluşan dense katmanından oluşmaktadır. Girdi katmanı geçmiş 7 günlük (1 hafta) güneş ışınım değerlerini kullanmaktadır. Girdi ile çıktı katmanının ilgili nöronu arasında kayıp fonksiyon olarak MSE ölçütü uygulanmaktadır. Optimizasyon algoritması olarak ADAM [28] kullanılmıştır. Ayrıca modelin öğrenme sürecinde epoch sayısı 150 ve yığın sayısı (batch size) 32 olarak belirlenmiştir. Önerilen modelde toplam 117025 adet parametrenin optimizasyonu yapılmıştır.

Önerilen LSTM modelin tahmin performansını değerlendirmek için 4 farklı istatistiki değerlendirme ölçütü kullanılmıştır. Bu ölçütler:

Ortalama mutlak hata (mean absolute error - MAE): Tahmin değerleri ile gerçek değerler arasındaki farkın ortalama mutlak sapmasını ifade etmektedir ve Eşitlik (8) kullanılarak hesaplanır.

$$MAE = \frac{1}{N} \sum_{i=1}^N |o_i - p_i| \quad 8$$

Ortalama karekök hata (root mean square error - RMSE): Genel olarak tahmin hatalarının standart sapmasını temsil etmektedir ve Eşitlik (9) kullanılarak hesaplanır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (o_i - p_i)^2}{N}} \quad 9$$

Ortalama mutlak yüzde hata (mean absolute percentage error - MAPE): Modellerin tahmin doğruluğunu yüzdesel olarak ölçer ve Eşitlik (10) kullanılarak hesaplanır.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{o_i - p_i}{o_i} \right| \quad 10$$

Belirleme katsayısı (coefficient of determination - r^2): Modellerin tahmin değerleri ile gerçek değerler arasındaki lineer ilişkinin gücünü temsil etmektedir ve Eşitlik (11) kullanılarak hesaplanır.

$$r^2 = 1 - \frac{\sum_{i=1}^N (o_i - p_i)^2}{\sum_{i=1}^N (o_i - \bar{o})^2} \quad 11$$

İstatistiki değerlendirme ölçütlerinin için kullanılan Eşitlik (8) - (11)'deki N örnek sayısı, o_i i . gözlemin gerçek değeri, p_i i . gözlemin tahmin değeri ve \bar{o} ise gerçek gözlem değerlerinin ortalamasını ifade etmektedir.

Bu çalışmada, makine öğrenmesi ve derin öğrenme uygulamalarında yaygın olarak başvurulan Python v3.6.7 programlama dili kullanılarak kodlanmıştır. Önerilen modeller Keras v2.2.4 [29] ve Scikit-learn v0.20.1 [30] kütüphaneleri kullanılarak uygulanmıştır.

4.3 Deneysel Sonuçlar (Experimental Results)

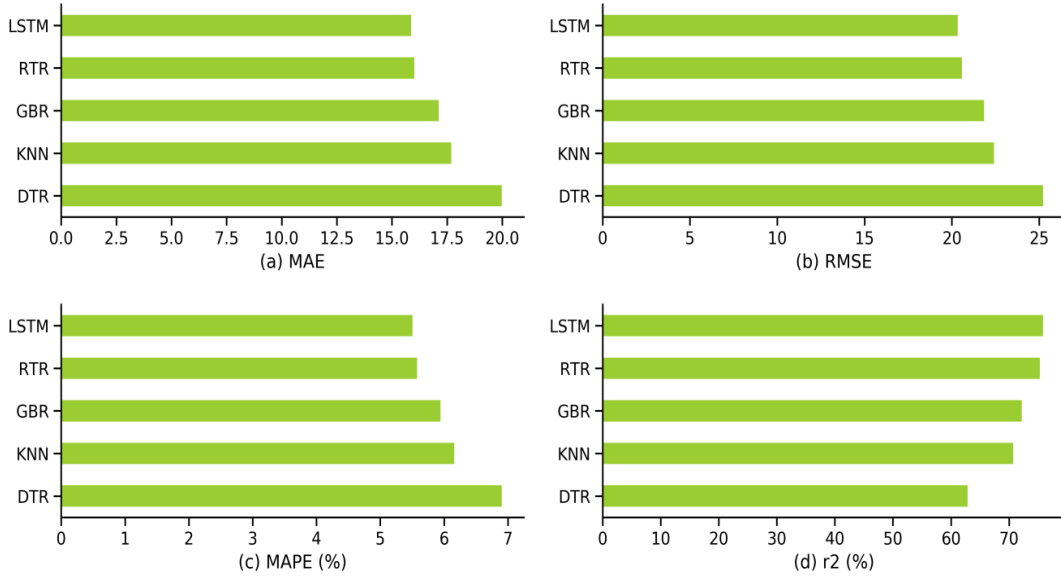
Bu kısımda, günlük güneş ışınım değerlerin tahmini için önerilen LSTM modelinin analizi ve değerlendirilmesi için yapılan benzetim çalışmalarından elde edilen sonuçlardan bahsedilecektir. Çorum ilinin güneş ışınım değerlerinin tahmini için önerilen LSTM ve diğer makine öğrenmesi modellerinde Y_t , t . gündeki tahmin edilen değeri ifade etmektedir. Bütün modellerde girdi bilgisi olarak geçmiş 7 güne ait güneş ışınım değerleri kullanılmaktadır.

Tablo 2. Modellerin performans karşılaştırması

		MAE	RMSE	MAPE (%)	r2
DTR	Değer	19.98	25.23	6.90	62.87%
	% Değişim	11.43%	11.18%	10.76%	12.47%
KNN	Değer	17.69	22.41	6.16	70.71%
	% Değişim	14.34%	13.42%	13.92%	14.79%
GBR	Değer	17.11	21.84	5.94	72.17%
	% Değişim	14.34%	13.42%	13.92%	14.79%
RTR	Değer	16.02	20.57	5.58	75.32%
	% Değişim	19.83%	18.47%	19.20%	19.80%
LSTM	Değer	15.87	20.34	5.51	75.88%
	% Değişim	20.56%	19.39%	20.25%	20.69%


Öncelikle, LSTM modelinin tahmin hatalarını değerlendirmek için diğer makine öğrenmesi modellerinin tahmin hataları ile karşılaştırıldı. Tablo 2'de modellerin performanslarını değerlendirmek için kullanılan MAE, RMSE, MAPE ve r^2 ölçütlerinin değer ve % değişim oranları verilmiştir. "Değer" satırında modellerden elde edilen ilgili performans ölçütlerinin sonuçları gösterilmektedir. Tablonun "% Değişim" satırında ise en düşük performans değerlerine sahip olduğu için temel model olarak belirlenen Karar

ağaçları modeline göre % değişimleri ifade etmektedir. Genel olarak sonuçlar incelendiğinde LSTM modelinin bütün performans ölçütlerinde en iyi sonuçları verdiği gösterilmiştir ve Karar ağacı sonuçları ile karşılaştırıldığında genel olarak % 20 daha üstün performans sergilemiştir. Önerilen model en yüksek performansını % 75.88'lik r^2 değerinde göstermiştir ve Karar ağacı modeline göre % 20.69 daha üstün olduğu görülmektedir. LSTM yaklaşımının diğer performans ölçütleri incelendiğinde MAE değeri 15.87, MAPE değeri % 5.51 ve RMSE değeri ise 20.34 olarak gösterilmiştir. LSTM modeline yakın 2. en iyi sonuçları veren Rastgele ağaçlar modeli olmuştur. Rastgele ağaçlar modelinin MAE, RMSE, MAPE ve r^2 değerleri sırasıyla; 16.02, 20.34, % 5.58 ve % 75.32'dir.



Şekil 4. Modellere ait performans ölçütlerinin grafiksel gösterimi

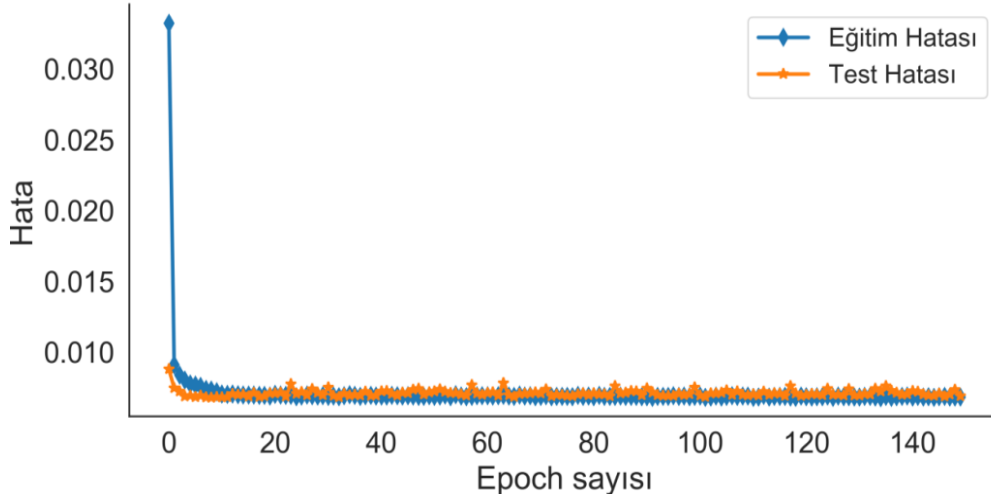
Şekil 4'de Derin öğrenme modeli ve makine öğrenmesi modellerinin performans ölçütleri değerlerinin grafiksel gösterimi verilmiştir. Şekilde de görüldüğü gibi tahmin hata ölçütleri olan MAE, MAPE ve RMSE değerlerinde en düşük sonuçları verirken belirlilik katsayısı olan r^2 değerinde en büyük yüzde değerini vermiştir. Diğer taraftan en düşük performans sergilen modelin Karar ağaçları olduğu söylenebilir. Genel olarak en iyi performansları gösteren modeller sırasıyla; LSTM, Rastgele ağaçları, K-En yakın komşu, Gradyan güçlendirme ve Karar ağaçlarıdır.



Şekil 5. Gerçek değerler ile LSTM modelin tahmin değerleri

Güneş ışınım değerlerinin tahmini için önerilen LSTM modelin tahmin değerleri ile gerçek değerleri gösteren zaman grafiği Şekil 5'de gösterilmiştir. Mart-2016 ve Aralık-2018 tarihleri arasındaki test

verilerinin gerçek değerleri ve LSTM tahmin değeri grafikte kullanılmıştır. LSTM modelin tahmin değerlerinin gerçek değerlere ile karşılaştırıldığında bir tutarlılık olduğu görülmektedir. Ayrıca tahmin ve gerçek değerlerin aynı eğilimi gösterdiği belirtilmiştir. Grafığe bakıldığında, 200 N/m² ile 350 N/m² değerleri dışındaki gerçek değerlerden göreceli olarak boşluklar olduğu söylenebilir.



Şekil 6. LSTM öğrenme eğrisi

Bu çalışmada önerilen modelin Aşırı öğrenme (Overfit) problemini önlemek için her bir epoch periyodunda eğitim örnekleri rastgele karıştırılmıştır. Bu durum modelin genelleme işlevini iyileştirmeye yardımcı oldu. Ayrıca modele doğruluk oranı önceden belirlenen miktarda tekrarlandığında erken durdurma kullanıldı. Bu yaklaşımlar modelin aşırı öğrenmesini azaltmada önemli derecede etkili olmuştur. Şekil 6'da önerilen modelin öğrenme eğrisi gösterilmektedir.

4. SONUÇ (CONCLUSION)

Yenilenebilir enerji kaynaklarından olan güneş enerjisinin elde edilmesi için kurulacak tesislerin fizibilite çalışması ile bu tesislerdeki çıktının planlaması ve yönetiminde güneş ışınım değerlerinin tahmini dikkate değer bir meseledir. Bu çalışmada, günlük güneş ışınım değerlerini tahmin etmek için derin öğrenme yaklaşımı olan LSTM modeli önerilmiştir. Önerilen modeli eğitmek ve performans değerlendirmesini yapmak için Çorum ilinin Temmuz-1983 ve Aralık-2018 tarihleri arasındaki 12969 adet günlük güneş ışınım verileri kullanılmıştır. Bu veriler, eğitim ve test setleri olmak üzere iki gruba taksim edilmiştir. Eğitim verileri sadece modelin öğrenme sürecinde kullanılırken, test verileri öğrenme sürecinde kullanılmamıştır. Modelin öğrenme süreci tamamlandıktan sonra algoritmanın performans değerlendirmesi yapılırken test verileri kullanılmıştır.

Derin öğrenme yaklaşımı olan LSTM modelin sonuçlarının doğruluğunu ve performansını değerlendirmek ve analiz etmek için literatürdeki en gelişmiş makine öğrenmesi algoritmaları olan Rastgele ağaçlar, K-En yakın komşu, Gradyan güçlendirme ve Karar ağaçları modelleri ile karşılaştırıldı. Yapılan benzetim çalışmaları sonucunda, önerilen LSTM modelinin tahmin performansı geleneksel makine öğrenmesi modelleri ile karşılaştırıldığında MAE, MAPE, RMSE ve r^2 performans ölçütlerinin hepsinde daha etkin değerler vermiştir. Diğer tarafta karar ağaçları modeli ise bütün kriterlerde en kötü performansı sergilemiştir. Önerilen LSTM modeli, Karar ağaçları modeli ile karşılaştırıldığında MAE, RMSE, MAPE ve r^2 kriterlerinde sırayla % 20.56, % 19.36, % 20.25 ve % 20,69 düzeyinde daha üstün sonuç göstermiştir.

Son olarak, gelecekteki çalışmalarda güneş ışınım verilerinin tahmin edilmesinde sıcaklık, rüzgâr hızı, basınç gibi özelliklerinin değerlendirmeye alınarak modelin geliştirilmesi düşünülmektedir. Ayrıca LSTM modelinin parametrelerinin meta-sezgisel algoritmalar kullanılarak optimize edilmesi önerilebilir.

KAYNAKLAR (REFERENCES)

- [1] Öztürk, M., Özek, N., & Berkama, B. (2012). Isparta için aylık ortalama günlük global güneş radyasyonu tahmininde mevcut olan bazı modellerin karşılaştırılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 18(1), 13-27.
- [2] Mengeş, H. O., & Sonmete, M. H. (2005). Konya'da aylık ortalama toplam güneş ışınımının tahmini için mevcut bazı modellerin karşılaştırılması. *Tarım Makinaları Bilimi Dergisi*, 1(3), 237-244.
- [3] Wen, C., Liu, S., Yao, X., Peng, L., Li, X., Hu, Y., & Chi, T. (2019). A novel spatiotemporal convolutional long short-term neural network for air pollution prediction. *Science of The Total Environment*, 654, 1091-1099.
- [4] Sagheer, A., & Kotb, M. (2019). Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing*, 323, 203-213.
- [5] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- [6] Aggarwal, S. K., & Saini, L. M. (2014). Solar energy prediction using linear and non-linear regularization models: A study on AMS (American Meteorological Society) 2013–14 Solar Energy Prediction Contest. *Energy*, 78, 247-256.
- [7] Mellit, A., & Pavan, A. M. (2010). A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar Energy*, 84(5), 807-821.
- [8] Lave, M., Kleissl, J., & Stein, J. S. (2012). A wavelet-based variability model (WVM) for solar PV power plants. *IEEE Transactions on Sustainable Energy*, 4(2), 501-509.
- [9] Salcedo-Sanz, S., Casanova-Mateo, C., Pastor-Sánchez, A., & Sánchez-Girón, M. (2014). Daily global solar radiation prediction based on a hybrid Coral Reefs Optimization–Extreme Learning Machine approach. *Solar Energy*, 105, 91-98.
- [10] Yadav, A. K., Malik, H., & Chandel, S. S. (2014). Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models. *Renewable and Sustainable Energy Reviews*, 31, 509-519.
- [11] Pedro, H. T., Coimbra, C. F., David, M., & Lauret, P. (2018). Assessment of machine learning techniques for deterministic and probabilistic intra-hour solar forecasts. *Renewable Energy*, 123, 191-203.
- [12] 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 Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7(1), 80-96.
- [13] Fernández, Á., Gala, Y., & Dorronsoro, J. R. (2014, September). Machine learning prediction of large area photovoltaic energy production. In *International Workshop on Data Analytics for Renewable Energy Integration* (pp. 38-53). Springer, Cham.
- [14] Gala, Y., Fernández, Á., Díaz, J., & Dorronsoro, J. R. (2016). Hybrid machine learning forecasting of solar radiation values. *Neurocomputing*, 176, 48-59.
- [15] Bouktif, S., Fiaz, A., Ouni, A., & Serhani, M. (2018). Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches. *Energies*, 11(7), 1636.

- [16] Gunduz, H., Yaslan, Y., & Cataltepe, Z. (2017). Intraday prediction of Borsa Istanbul using convolutional neural networks and feature correlations. *Knowledge-Based Systems*, 137, 138-148.
- [17] Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
- [18] Kim, K., Kim, D. K., Noh, J., & Kim, M. (2018). Stable Forecasting of Environmental Time Series via Long Short Term Memory Recurrent Neural Network. *IEEE Access*, 6, 75216-75228.
- [19] Qing, X., & Niu, Y. (2018). Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. *Energy*, 148, 461-468.
- [20] Alzahrani, A., Shamsi, P., Dagli, C., & Ferdowsi, M. (2017). Solar irradiance forecasting using deep neural networks. *Procedia computer science*, 114, 304-313.
- [21] Pascanu, R., Mikolov, T., & Bengio, Y. (2013, February). On the difficulty of training recurrent neural networks. In *International conference on machine learning* (pp. 1310-1318).
- [22] Xiao, Y., & Yin, Y. (2019). Hybrid LSTM Neural Network for Short-Term Traffic Flow Prediction. *Information*, 10(3), 105.
- [23] Ayata, D., Saraçlar, M., & Özgür, A. (2017, May). Political opinion/sentiment prediction via long short term memory recurrent neural networks on Twitter. In *2017 25th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- [24] Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22.
- [25] Hastie, T., & Tibshirani, R. (1996). Discriminant adaptive nearest neighbor classification and regression. In *Advances in Neural Information Processing Systems* (pp. 409-415).
- [26] Friedman, J. H. (2002). Stochastic gradient boosting. *Computational statistics & data analysis*, 38(4), 367-378.
- [27] Gunaydin, O., Ozbeyaz, A., & Soylemez, M. (2019). Estimating California Bearing Ratio Using Decision Tree Regression Analysis Using Soil Index and Compaction Parameters. *International Journal of Intelligent Systems and Applications in Engineering*, 7(1), 30-33.
- [28] Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [29] F. Chollet, Keras, (2015). GitHub repository, <https://github.com/fchollet/keras>.
- [30] Pedregosa, Fabian, et al. (2011). Scikit-learn: Machine learning in Python. *Journal of machine learning research*, 12(Oct), 2825-2830.