



Hibrit derin öğrenme yöntemi kullanılarak hiperparametre optimizasyonu ile yenilenebilir elektrik enerjisi tahmini

Renewable electric energy estimation by hyperparameter optimization using hybrid deep learning method

Kübra Kaysal¹, * , Ahmet Haşim Yurttakal² , Fatih Onur Hocaoglu³ 

¹ Afyon Kocatepe Üniversitesi, Afyon Meslek Yüksekokulu, Elektrik Bölümü, 03200, Afyonkarahisar Türkiye

² Afyon Kocatepe Üniversitesi, Bilgisayar Mühendisliği Bölümü, 03200, Afyonkarahisar Türkiye

³ Afyon Kocatepe Üniversitesi, Elektrik Mühendisliği Bölümü, 03200, Afyonkarahisar Türkiye

Öz

Enerji kaynaklarının düzensiz ve bilinçsiz kullanımı çevresel tahribatlara sebep olurken, artan nüfus yoğunluğu, sanayi ve teknolojinin gelişmesi de her geçen gün elektrik enerjisi talebini artırmaktadır. Bu amaçla enerji sektörü, yatırımlarını hem çevre dostu hem de arz-talep dengesini sağlamak adına rüzgâr enerjisi gibi yenilenebilir enerji kaynaklarına yönelmektedir. Rüzgâr enerjisinden elde edilen enerji miktarı rüzgârın yönü ve hızı gibi bölgesel farklılıklara bağlı olarak değişkenlik göstermektedir. Bu çalışmada, rüzgâr enerjisinden elektrik üretimi tahmininde daha iyi sonuçlar elde etmek amacıyla rüzgâr enerjisinin doğrusal ve durağan olmayan yapısını yakalamak için derin öğrenme metodlarından CNN ve BLSTM mimarilerinin hibrit bir şekilde kullanıldığı bir yöntem önerilmektedir. Tahmin modelinde, saatlik frekansta ölçülmüş 26280 adet gerçek zamanlı veri kullanılmıştır. Ayrıca tahmin başarısını artırmak adına modelde kullanılan hiperparametre değerleri Grid Search arama algoritması kullanılarak optimize edilmiştir. Önerilen hibrit modelin başarısı BLSTM modeli ile kıyaslanmıştır. Sonuç olarak önerilen CNN-BLSTM modelinin başarı oranını gösteren R² değeri 0.984 olarak hesaplanmıştır.

Anahtar kelimeler: Yenilenebilir elektrik enerjisi, Derin öğrenme, Hiperparametre optimizasyonu

1 Giriş

Mikro şebekeler yerel ve bağımsız elektrik üretim ve dağıtım ağlarıdır. Bu şebekelerde üretim ve talep arasında denge sağlanması sistemin sağlıklı ve sorunsuz çalışması için oldukça önemlidir. Akıllı ve mikro şebekelerin gelişmesi ve yaygınlaşması, sürdürülebilir ve çevre dostu enerji kaynaklarının, özellikle yenilenebilir enerji kaynaklarının kullanımını teşvik eder. Yenilenebilir enerji sistemleri, doğal kaynaklardan elde edilen enerjiyi kullanarak çevresel etkileri azaltır ve enerji üretimini daha sürdürülebilir hale getirir. Bu nedenle, akıllı ve mikro şebekelerin gelişimi, yenilenebilir enerji sistemlerinin önemini vurgulayan bir adımdır ve yatırım şirketlerinin enerji yönetimini doğru planlamalarına destek sağlar. [1].

Abstract

The unregulated and unconscious use of energy sources causes environmental damage. On the other hand the increasing population density, development of industry and technology increase the demand for electrical energy day by day. For this purpose, investments in the energy sector are directed towards renewable energy sources such as wind energy in order to ensure both environment-friendly and supply-demand balance. The amount of energy obtained from wind energy varies depending on regional differences such as wind direction and speed. In this study, a method is proposed to achieve better results in predicting electricity generation from wind energy by capturing the non-linear and non-stationary nature of wind energy using a hybrid approach of deep learning methods, specifically CNN and BLSTM architectures. In the forecasting model, 26280 real-time data measured at hourly frequency are used. In addition, the hyperparameter values used in the model were optimized using the Grid Search algorithm in order to increase the prediction success. The success of the proposed hybrid model is compared with the BLSTM model. As a result, the R² value, which indicates the success rate of the proposed CNN-BLSTM model, was calculated as 0.984.

Keywords: Renewable electric energy, Deep learning, Hyperparameter optimization

Elektriğin talepten fazla üretilmesi durumunda, bataryalarda depolanması ekonomik olmamakla birlikte elektriğin büyük ölçekte depo edilmesinde henüz pratik ve ekonomik bir çözüm bulunamamıştır. Ayrıca elektriğin talebe göre yetersiz üretilmesinde elektrik kesintileri meydana gelmektedir. Bu nedenle arz ve talebin gerçek zamanlı olarak dengelenmesi gerekir. Bu dengenin sağlanması için nerede ne zaman ve ne kadar elektriğe ihtiyaç olduğu bilinmelidir. Arz- talep yönetiminde doğru ve güvenilir tahmin modelleri olmadan sürdürülebilir elektrik enerjisinden bahsetmek mümkün değildir [2]. Öte yandan teknolojinin gelişmesiyle birlikte Makine öğrenmesi ve Derin öğrenme tabanlı tahmin modelleri giderek popüler hale gelmiştir. Makine öğrenmesi, veriler üzerinden

* Sorumlu yazar / Corresponding author, e-posta / e-mail: kubra543@hotmail.com (K. Kaysal)

Geliş / Recieved: 11.03.2023 Kabul / Accepted: 19.06.2023 Yayınlanma / Published: 15.07.2023

doi: 10.28948/ngumuh.1263782

karmaşık örüntü yapılarını öğrenerek yüksek doğruluk oranına sahip, hızlı ve kullanıcıdan bağımsız şekilde yeni tahminlerde bulunabilir. Derin öğrenme ise bir veya daha fazla gizli katmana sahip yapay sinir ağlarına benzer makine öğrenmesi algoritmalarının yeni bir alt dalıdır. Bu algoritmaların performansına etki eden çeşitli hiperparametreler bulunmaktadır. Elektrik üretim verilerinden zaman serisi modellerini geliştirmek, geliştirilen modellerin hiperparametre değerlerini doğru seçebilmek tahminin başarısını artırmaktadır [3].

Derin öğrenme gibi Yapay Zekâ temelli öğrenme algoritmalarında çözülmesi gereken bir problem öncelikle optimizasyon problemine dönüştürülür, sonrasında ise problemin çözülmesi için farklı optimizasyon yöntemleri kullanılır [4]. Öğrenme algoritmalarının her geçen gün gelişmesi ve parametre optimizasyonunun öneminin artması ile çeşitli optimizasyon algoritmaları geliştirilmiş ve tahmin modelleri üzerinde kullanılmıştır. Literatürde hiperparametre optimizasyonu için Bayes algoritması [5,6], Izgara arama algoritması [7], Genetik algoritma [8], Gri kurt optimizasyon algoritması [9], Rastgele arama algoritması [10] gibi optimizasyon yöntemleri yaygın olarak kullanılmaktadır.

Günümüzde sağlık, ekonomi, eğitim gibi birçok alanda derin öğrenmeye dayalı tahmin modelleri kullanılmaktadır. Ayrıca hayatın her alanında büyük bir yere sahip olan elektrik üretimindeki karmaşık problemlerin çözümünde de bu modeller araştırmacıların ilgisini çekmektedir. Gao vd. [11] gerçekleştirdiği çalışmada, veriye dayalı taşkın tahmini için Tekrarlayan Sinir Ağları (RNN), Uzun-Kısa Süreli Hafıza (LSTM) ve Kapılı Yinelemeli Üniteler (GRU) modelleri kullanmış ve modellerin performanslarını kıyaslamıştır. Tahminde kullanılan veriler, 2000-2014 yılları arasında saatlik frekansta ölçülen gerçek zamanlı verilerdir. Kısa dönemli akış tahminlerinde model eğitimi için daha az zaman gerektiğinden çalışma için önemli parametrelerden biri olan zaman adımı optimize edilmiştir. Sonuç olarak GRU, LSTM kadar iyi performans gösterdiği gibi hız açısından da başarılı sonuçlar sergilemiştir. Jalali vd. [12] tarafından gerçekleştirilen bir çalışmada, akıllı yük tahmini için yeni bir model geliştirilmiştir. Tahminde 2018 yılına ait gerçek zamanlı elektrik tüketim verileri kullanılmıştır. Önerilen modelde yük tahmini doğruluğunu artırmak için çeşitli hiperparametre değerleri Gri Kurt optimizasyon metodu ile belirlenmiş ve Evrimsel Sinir Ağları (CNN) modeli ile tahmin edilmiştir. Tahmin performansını değerlendirmek için geliştirilen model, LSTM ve RNN ile karşılaştırılmıştır. Önerilen modelin performansı diğer modellere göre daha başarılı bulunmuştur. Ribeiro vd. [13] yük tahmini için yaptıkları çalışmada Bayes optimizasyon algoritması kullanmışlardır. Tahmin için iki farklı veri seti kullanılmıştır. İlk veri seti Polanya elektrik tüketim verileridir ve 1601 örnekten oluşmaktadır. İkinci veri seti Brezilya tüketim verileridir ve 672 örnekten oluşmaktadır. Tahminde derin öğrenme modellerinden RNN modeli kullanılmış ve kısa dönem yük tahmini için önerilen model oldukça başarılı bulunmuştur. Literatüre katkısı olan bir diğer çalışmada Kosanoğlu vd. [14], dört farklı RNN modelini rüzgâr enerjisi üretim tahminlemesi için

kullanmışlardır. Çalışmada gerçek zamanlı veriler kullanılarak kısa vadeli rüzgâr hızı tahmini yapılmıştır. Geleneksel tahmin modelleri ile RNN sonuçları kıyaslandığında RNN modellerinin tahminlemede daha başarılı olduğu sonucuna varılmıştır.

Bu çalışmada, küçük bir bölgenin rüzgâr çiftliklerinden elde edilen gerçek zamanlı üretim verileri ile kısa dönem elektrik üretim tahmini yapılmıştır. Bu kapsamda, yapay zeka tabanlı CNN ve Çift Yönlü Uzun Kısa Süreli Hafıza (BLSTM) mimarilerinin hibrit bir yapısı oluşturulmuş ve ağ mimarisinin hiperparametreleri Grid Search arama algoritması ile optimize edilmiştir. Doğruluk değerleri 10 katmanlı çapraz doğrulama yöntemi kullanılarak doğrulanmıştır. Farklı derin öğrenme modelleri kullanılarak önerilen modelin performansı kıyaslanmıştır. Söz konusu modellerin oluşturulması ve çalıştırılmasında Python yazılımından yararlanılmıştır.

Makalenin organizasyonu şu şekildedir: materyal ve metod başlığı altında derin öğrenme modelleri, önerilen hibrit model, kullanılan veri, optimizasyon tekniği ve performans metrikleri açıklanmıştır. Sonuçlar başlığı altında; hiperparametre optimizasyonundan ve oluşturulan modellerden elde edilen sonuçlar paylaşılmıştır. Son olarak tartışma bölümünde sonuçlar analiz edilerek yorumlanmıştır.

2 Materyal ve metod

2.1 Evrimsel sinir ağları

CNN, görüntü ve veri üzerinde çeşitli özelliklerin algılanmasını sağlayan ve birçok çalışma alanında tercih edilen bir yapay sinir ağı modelidir. Bir veri setinden veya görüntüden çeşitli filtreler ve katmanlar kullanarak özellik tespit etmeye çalışmaktadır. CNN'de özellik çıkarımı için çeşitli katmanlar kullanılmaktadır. Bu katmanlardan, evrimsel katmanı resim veya veri üzerine uygulanan filtreler sayesinde verilerden özellik çıkarımı yapmaktadır. Oluşturulan filtre giriş verisinin sol köşesinden başlayarak tüm veri üzerinde gezdirilir, filtre ve karşılıklı veri değerleri birbiri ile çarpılıp çıkan sonuçlar toplanarak çıktı matrisinde depolanır [15]. Modele, doğrusal olmayan fonksiyonların tanıtılması için evrimsel katmanından sonra aktivasyon fonksiyonu ve boyut küçültmek için havuzlama katmanı eklenmektedir. Havuzlama katmanının çıkışından elde edilen veri sinir ağına öğrenme işlemi gerçekleştirmek için tam bağlantılı katmana gönderilir [16].

2.1 Çift yönlü uzun kısa süreli hafıza

Yinelemeli sinir ağlarından biri olan LSTM mimarisi, RNN mimarisindeki kısa süreli hafıza problemlerini ortadan kaldırmak amacıyla geliştirilmiştir. Yinelemeli sinir ağlarında katman sayısı arttıkça Gradyan yok olması problemi ortaya çıkmaktadır. Bu da ağı eğitilemez hale gelmesine sebep olmaktadır. LSTM mimarisi bu problemi çözmek için geliştirilmiştir [17,18]. Tipik bir LSTM ağı hücreler olarak adlandırılan bellek yapılarından oluşur. Veriler LSTM yapısında bulunan kapılar aracılığı ile hücre durumuna eklenebilir veya çıkarılabilir. Bir LSTM ağı oluşturulurken öncelikle gerekli olmayan ve hücreden çıkarılacak bilgiler belirlenir. Bu işlemi yapan kısım unutmama

kapısı olarak adlandırılır. Matematiksel ifadesi **Denklem 1**'deki gibi elde edilir [19,20].

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

Bir LSTM mimarisinde h_{t-1} LSTM biriminin son çıktısını, x_t t zamanda mevcut girdiyi ifade etmektedir. f_t unutma kapısı, σ sigmoid fonksiyonu, b_f bias ve W_f unutmaya kapısının ağırlık matrisleridir.

Hücre durumuna yeni bilgiler eklendiğinde eski bilgiler unutulur. Giriş kapısı olarak adlandırılan hücre bu işlemi yapmaktadır. Bu kapı yeni bilginin ne ölçüde korunması gerektiğine karar verir ve bunu σ sigmoid fonksiyonu ile belirler. **Denklem 2**'de giriş kapısının matematiksel ifadesi verilmiştir [19,20].

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

i_t giriş kapısı, b_i bias ve W_i giriş kapısının ağırlık matrisleridir.

LSTM mimarisindeki bir diğer kapı çıkış kapısıdır. Bu kapı hangi bilginin çıkışa aktarılacağına karar verir. Matematiksel ifadesi **Denklem 3**'de verilmiştir [19,20].

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (3)$$

o_t çıkış kapısı, b_o bias ve W_o çıkış kapısının ağırlık matrisleridir. Ayrıca yeni hücre durumu **Denklem 4**'deki gibi hesaplanır [19,20].


$$C'_t = \tanh(W_c [h_{t-1}, x_t] + b_c) \quad (4)$$

C'_t hücre durumu adayı, W_c ve b_c sırasıyla hücre durumu adayının hesaplanması için ağırlık matrisi ve biastır. En son hücre ise güncelleme kapısıdır(C_t) ve **Denklem 5**'de verilmiştir [19,20].

$$C_t = f_t * C_{t-1} + i_t * C'_t \quad (5)$$

Çift yönlü LSTM'ler (BLSTM), zaman serisi problemlerinde aynı giriş verisi üzerinde iki LSTM çalıştırır. BLSTM ağı, bir LSTM hücresi kümesinin hem doğrudan hem de ters sıralanmış bir versiyonunu içerir. Bu hem geçmiş hem de gelecek verilerin işlenebildiği bir dizi zaman serisi verisi boyunca ağı girdisini işleyebilir. İlk LSTM, giriş verileri üzerinde arkadan ileriye doğru çalışmaktadır. İkinci LSTM ise aynı veriler üzerinde ileriye doğru çalışmaktadır. İki yönlü LSTM aynı giriş verisi üzerinde iki LSTM birden çalıştırıldığı için tek yönlü LSTM'den daha hızlı çalışmaktadır [21]. **Şekil 1**'de BLSTM modeline ait blok şeması verilmiştir.

Bu çalışmada, tahmin modelleri oluşturulurken BLSTM ve CNN-BLSTM mimarisi hibrit bir şekilde oluşturulmuştur. Model başarısını artırmak için doğruluk değerleri 10 katmanlı çapraz doğrulama yöntemi kullanılarak doğrulanmıştır. Kurulan model içerisindeki hiperparametreler Grid Search arama algoritması ile optimize edilmiştir.




Şekil 1. BLSTM blok şeması

2.2 Önerilen tahmin modeli

CNN-BLSTM (Convolutional Neural Network - Bidirectional Long Short-Term Memory) modelleri, zaman serisi verileri gibi yapısal özelliklere sahip veriler için etkili bir tahminleme aracıdır. Bu model, hem evrişim ağı (CNN) hem de uzun-kısa süreli bellek (LSTM) mimarilerini bir araya getirerek, zaman serilerindeki ilişkileri yakalayabilir ve uzun vadeli bağımlılıkları hesaplayabilir [22-24]. Elektrik üretimi tahmini gibi sürekli ve dinamik değişkenlere dayalı bir tahminleme problemi için, CNN-BLSTM modeli etkili bir seçimdir. Bu model, birkaç farklı veri kaynağından (örneğin, hava durumu, fiyatlar, tüketim verileri) gelen girdileri işleyebilir ve enerji talebinin belirlenmesinde kullanılabilir.

Çalışmada kullanılan tahmin modelinin akışı şu şekilde gerçekleştirilmiştir; veri toplama ve normalleştirme, eğitim ve test verilerinin oluşturulması, hiperparametre optimizasyonu, hibrit modelin kurulması, performansların değerlendirilmesidir. Önerilen tahmin modelinin blok şeması **Şekil 2**'de verilmiştir.



Şekil 2. CNN-BLSTM blok şeması

BLSTM ve CNN mimarileri, yüksek hassasiyette tahmin yapma özelliğine sahip modellerdendir [25,26]. Bu yapıdan dolayı veri dizileri içerisinde çeşitli gizli özellikler çıkarılabilen ve daha doğru tahminler yapmayı sağlayabilen hibrit bir model oluşturulması amaçlanmıştır. Modelde CNN katmanı, üretim verilerinin yerel eğilimini yakalamak için kullanılmıştır. BLSTM katmanı ise uzun vadeli veri değişimlerini öğrenmek için tasarlanmıştır.

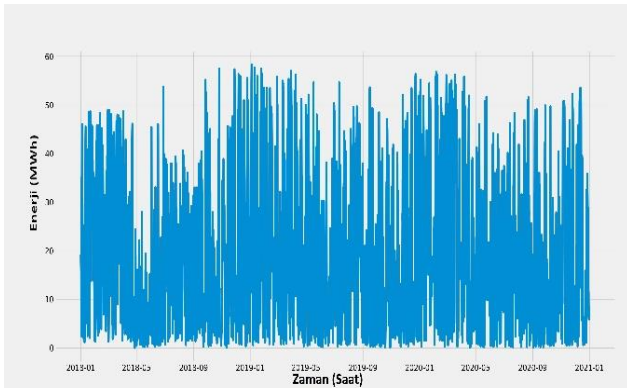
Tahmin sonuçları ise Dense katmanından sonra gerçekleştirilmiştir. Modelde öznetelik çıkarımı için iki adet çekirdek filtresi her bir evrişim katmanı optimizasyon sonucu elde edilen neuron sayısı ile belirlenmiştir. Evrişim işleminden sonra bir adet maxpooling işlemi yapılmış ve veriler vektör formatına dönüştürülmüştür. Vektör formatına dönüştürülen veriler BLSTM tahminleyicisine girdi olarak sunulmuştur.

2.3 Veri toplama ve veri normalleştirme

Bu çalışmada, Akdeniz bölgesinde kurulu olan bir rüzgâr çiftliğinden 01 Ocak 2018 – 31 Aralık 2020 tarihleri arasında elde edilen gerçek zamanlı enerji üretim verileri kullanılmıştır. Veriler saatlik periyotlarla ölçülmüştür. Santralin enerji üretim kapasitesi yıllık 216 GWh'tir. Santral yaklaşık 52000 kişiye karşılık düşen elektrik enerjisi ihtiyacını karşılamaktadır. Önerilen metotta toplam 26280 adet veri kullanılmıştır. Verilerin normal dağılım sergileyebilmesi ve tahmin başarımını artırması için veriler üzerinde normalizasyon işlemi yapılmıştır. Normalleştirme işlemi 0 ile 1 arasında gerçekleştirilmiştir ve Denklem 6'daki gibi hesaplanmıştır.

$$\text{Normalized data} = \frac{\text{real data} - \text{mindata}}{\text{maxdata} - \text{mindata}} \quad (6)$$

Şekil 3'de çalışmada kullanılan veri seti sunulmaktadır.



Şekil 3. Saatlik elektrik enerjisi üretimi

2.4 Hiperparametre optimizasyonu

Derin öğrenme yöntemleri ile çok katmanlı mimari yapılarda, araştırmacı tarafından karar verilmesi gereken birden fazla hiperparametre grubu bulunmaktadır. Bu hiperparametrelerin değerinin ne olacağına karar vermek oldukça zor ve zaman alıcıdır. Hiperparametre optimizasyonu, makine öğrenmesi ve derin öğrenme gibi algoritmaların performansını iyileştirmek için kullanılan bir yöntemdir. Hiperparametreler, modelin öğrenme sürecini etkileyen parametrelerdir ve bu nedenle, doğru hiperparametre ayarları modelin performansını önemli ölçüde etkileyebilir [27,28].

Izgara arama optimizasyonu (Grid Search Optimization), makine öğrenimi ve yapay zekâ alanında sık kullanılan bir hiperparametre ayarlama yöntemidir. Hiperparametreler, bir makine öğrenimi algoritmasının performansını etkileyen ve

önceden belirlenmiş olan parametrelerdir. Örnek olarak, bir makine öğrenimi algoritması için öğrenme oranı, epoch sayısı, mini-batch boyutu gibi hiperparametreler hesaplanabilir [27,28].

Izgara arama, farklı hiperparametre kombinasyonlarını deneyerek en iyi sonucu veren hiperparametre değerlerini bulmaya çalışır. Bu yöntemde, hiperparametrelerin olası değerleri önceden belirlenir ve bu değerlerin her biri diğer hiperparametrelerle birlikte kombinasyon halinde denir. Böylece, tüm hiperparametrelerin olası değerleri üzerinde bir "izgara" oluşturulur ve her noktadaki hiperparametre kombinasyonu denir [27,28]. Parametre optimizasyonu için kullanılan algoritma yapısı Tablo 1'de verilmiştir.

Tablo 1. Algoritma yapısı

Önerilen Modelin Sözde Kodları	
Girdi:	Enerji verileri
Çıktı:	Enerji üretim tahmini modelinde parametre optimizasyonu
1	loopback dizisini tanımla
2	nöron sayısını tanımla
3	epoch sayısını tanımla
4	batch size boyutunu tanımla
5	uzunluk dizisini tanımla
6	loopback değişkeni l'den i'ye kadar
7	nöron değişkeni l'den j'ye kadar
8	epoch değişkeni l'den k'ya kadar
9	batch size değişkeni l'den l'ye kadar
10	uzunluk değişkeni l'den m'ye kadar
11	i, j, k, l, m parametrelerini hesapla
13	performans metriklerini bul
14	diğer sonuçlarla kıyasla
15	Döngü sonu
16	Döngü sonu
17	Döngü sonu
18	Döngü sonu
19	Döngü sonu

2.5 Performans metrikleri

Geliştirilen algoritmalarından elde edilen sonuçların performansını karşılaştırmak amacıyla dört farklı istatistiksel değerlendirme ölçütü kullanılmıştır. Bu çalışmada kullanılan değerlendirme ölçütleri Tablo 2'de verilmiştir [29,30].

Tablo 2'de verilen denklemlerde, N tahmin edilen yükteki veri sayısını, Y_L tahmin edilen yükün büyüklüğünü, \hat{Y}_L herhangi bir andaki gerçek büyüklüğü ve A_L ortalama değeri vermektedir.

Tablo 2. Makalede kullanılan performans metrikleri

Metrik	Denklem
Ortalama Mutlak Hata (MAE)	$MAE = \frac{1}{N} \sum_{L=1}^N (Y_L - \hat{Y}_L) $
Kök Ortalama Kare Hatası (RMSE)	$RMSE = \sqrt{\frac{1}{N} \sum_{L=1}^N (Y_L - \hat{Y}_L)^2}$
Ortalama Mutlak Yüzdesele Hata (MAPE)	$MAPE = \frac{\sum_{L=1}^N (Y_L - \hat{Y}_L) }{N} \times 100$
R ²	$R^2 = 1 - \frac{\sum_{i=1}^N (Y_L - \hat{Y}_L)^2}{\sum_{i=1}^N (Y_L - A_L)^2}$

3 Sonuçlar

Bu çalışmada elektrik üretim tahmin modellerinde yüksek başarı performansı için çeşitli modeller geliştirilmiştir. Önerilen tahmin modeli, CNN-BLSTM hibrit modeldir. Bu model, evrişim ağı ve uzun-kısa süreli bellek mimarilerini bir araya getirerek zaman serilerindeki ilişkileri yakalayabilir ve uzun vadeli bağımlılıkları hesaplayabilir. CNN katmanı, veri dizilerinin yerel eğilimlerini yakalamak için kullanılırken, BLSTM katmanı uzun vadeli veri değişimlerini öğrenmek için tasarlanmıştır. Bu sayede, model kısa vadede daha doğru tahminler yapabilmektedir.

Ayrıca, bu modellerin mimari yapısında bulunan hiperparametre değerlerinin iyi seçilmesi tahmin başarısında oldukça etkilidir. Bir BLSTM mimarisinde nöron sayısı, epoch değeri, batch_size gibi parametre değerleri model performansını artıran önemli parametrelerdendir [31]. Önerilen model içerisinde bulunan bu değerler Izgara arama algoritması ile optimize edilmiştir. Optimize edilen hiperparametre değerler aralığı Tablo 3'deki gibi verilmiştir.

Tablo 3. Hiperparametre aralığı

Parametre	Aralık değeri
Batch_Size	[10 20 40 60 80]
Epoch	[10 15 20]
Nöron	[10 20 30 40 50]
Loopback	[24 48]

Optimizasyon algoritması, farklı hiperparametre kombinasyonları için RMSE, MAE, MSE ve R^2 gibi hata metriklerini hesaplamış ve en iyi sonuçları veren parametre değerleri belirlenmiştir. Çalışmada elde edilen başarılı sonuçlar, batch_size için 10, epoch değeri için 15 ve nöron sayısı için 50 olduğunda elde edilmiştir.

3.1 Model sonuçları

Önerilen tahmin modellerin doğruluğu ve güvenilirliği adına derin öğrenme modellerinde aynı veri seti ve aynı parametre değerleri kullanılmıştır. Önerilen model için ezberin önüne geçebilmek ve daha doğru eğitim sonuçları alabilmek adına dropout parametresi 0.2 olarak seçilmiştir. EarlyStopping kendini tekrarlayan 7 adım sonunda eğitimi durdurmaktadır. Aşırı öğrenme ve ezberin yorumlanabilmesi için önerilen modelin Loss eğrisi çizdirilmiştir. Elde edilen grafik Şekil 4'de verilmiştir. Şekle göre eğitim süreci boyunca eğitim kayıp değeri ile birlikte test kayıp değerinin de azaldığı görülmektedir. Bu da eğitim süreci boyunca overfitting olmadığını göstermektedir. Önerilen CNN-BLSTM tahmin modelinde elde edilen tüm veri için orjinal değerler ile eğitim ve test tahmin değerlerinin grafiği Şekil 5'te verilmiştir.

Tahminde kullanılan her bir modelin hata metrikleri ve başarı oranları hesaplanmıştır. En iyi performansı sergileyen modelin tespiti için bu kriterler kıyaslanmıştır. Bu kıyaslama sonucunda da her hata metriği için en küçük değeri ve başarı oranı en yüksek değeri yine CNN-BLSTM

hibrit mimari modeli sergilemiştir. Elde edilen metrik değerlerinin sonuçları Tablo 4'de verilmiştir. RMSE değeri 1.60, MSE değeri 2.56, MAE değeri 1.18 ve R^2 oranı %0.984 değerleri ile hibrit CNN-BLSTM modelinin başarısı BLSTM modeline göre yüksek tahmin sonuçları vermiştir.

Modelin eğitim süreci boyunca overfitting olmaması, ezberi önlemesi ve daha doğru tahmin sonuçları elde etmesi, modeli güvenilir ve etkili bir tahmin aracı haline getirmiştir. Dropout parametresinin uygun bir değerle kullanılmasıyla, aşırı öğrenme sorunu minimize edilirken modelin genelleme kabiliyeti artırılmıştır. EarlyStopping mekanizması da eğitimi tekrarlayan adımlar sonunda durdurarak gereksiz hesaplama süresini azaltırken, en iyi modelin seçilmesini sağlamaktadır.

Sonuç olarak, önerilen CNN-BLSTM modeli güvenilir ve doğru tahmin sonuçları elde etmek için etkili bir seçenektir. Eğitim sürecinde overfitting'i engelleyen, doğru parametre ayarlamaları ve model mimarisıyla ezberi önleyen bu model, zaman serisi tahmini alanında başarılı sonuçlar elde etmek için tercih edilebilir.


4 Tartışma

Bu çalışmada, küçük bir bölgede kurulu olan rüzgâr santralinden elde edilen gerçek zamanlı veriler kullanılarak kısa dönemli elektrik üretimi tahmin edilmiştir. Tahminde optimum parametre değerini tespit edebilmek için hiperparametre değerleri ızgara arama algoritması ile optimize edilmiştir.

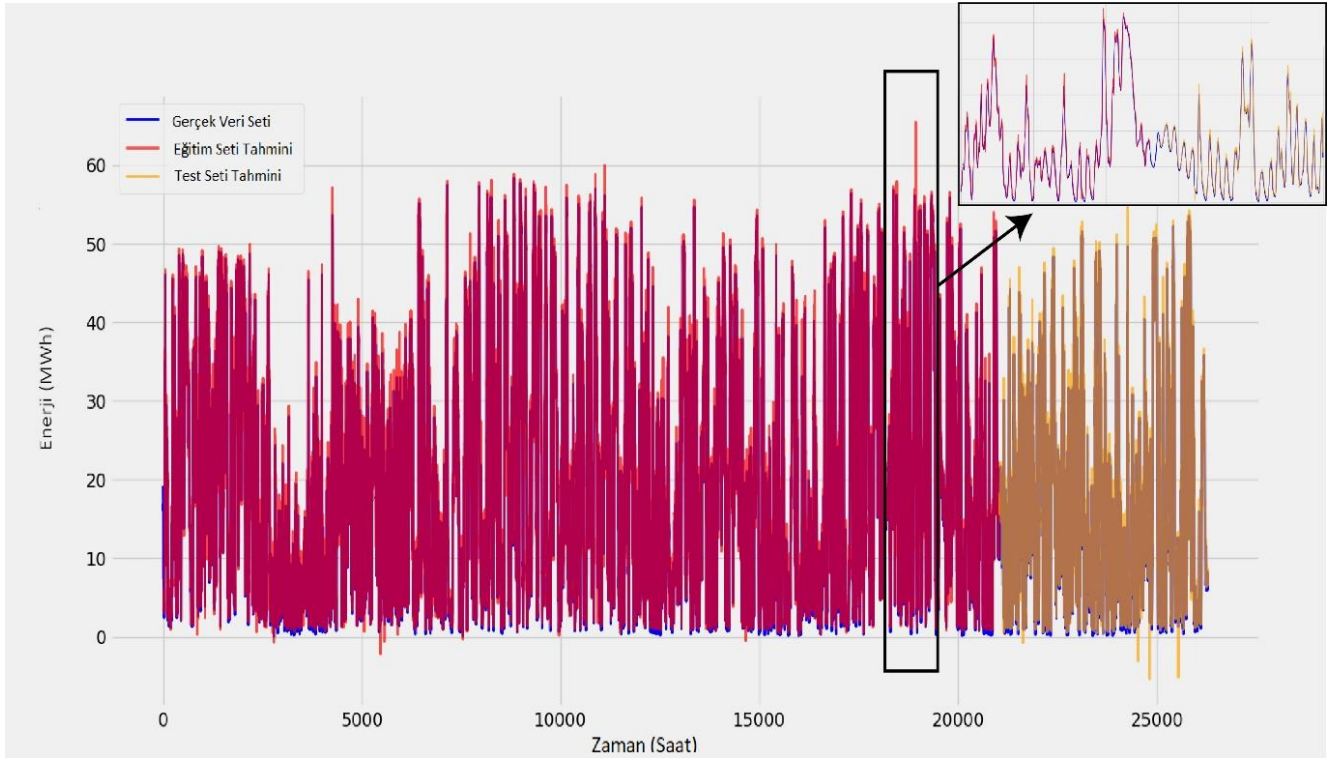
Model içinde kullanılan hiperparametrelerin optimize edilmesi, minimum parametre ile yüksek doğruluk sonuçlarına ulaşılmıştır. BLSTM model ve hibrit modelin performansı karşılaştırılmış ve önerilen hibrit modelin R^2 değeri oldukça başarılı bulunmuştur. Özellikle R^2 oranının yüksek olması, modelin tahminlerinin gerçek değerlerin büyük kısmını açıklama yeteneği olduğunu göstermektedir.

Doğru elektrik enerjisi üretimi tahmini, şebekelerde karar verme ve sistem işleyişi için kritik öneme sahiptir. Ayrıca arz- talep dengesinin verimli bir şekilde sağlanabilmesi için operatörler, tahmin modelleri ile yatırımcılar için ideal bir pazar stratejisi oluşturabilirler. Bu çalışmada, rüzgâr enerjisi santrallerinden üretilen elektrik enerjisinin tahmini için hibrit bir CNN-BLSTM modeli önerilmiştir. Kısa dönem elektrik üretim tahmini için önerilen hibrit modelde tahmin başarısını etkileyen hiperparametre değerleri Grid Search arama algoritması ile optimize edilip minimum maliyet ile başarılı sonuçlar elde edilmiştir. Doğrulama değerleri 10 katmanlı çapraz doğrulama ile doğrulanmıştır. Farklı derin öğrenme modelleri kullanılarak önerilen modelin performansı kıyaslanmıştır. Sonuç olarak hibrit modelin performansı 0,984 doğruluk oranı ile BLSTM modele göre daha başarılı bulunmuştur.

Bir CNN-BLSTM modeli kullanarak elektrik üretimi tahmini yapmak, doğru veri toplama ve ön işleme, model oluşturma, eğitim ve tahminler yapma aşamalarını gerektirir. Bu, birçok uygulama alanında yararlı olabilir, çünkü bu model, zaman ve uzamsal verileri işleyebilir ve çeşitli alanlarda kullanılabilir.



Şekil 4. Eğitim ve test verisi kayıp eğrileri



Şekil 5. Tahmin sonucu

Tablo 4. Modellerin karşılaştırmalı performans sonuçları

Tahmin Modeli	RMSE (MWh)	MSE(MWh)	MAE(MWh)	R^2
BLSTM	1.84	3.38	1.34	0.980
CNN-BLSTM	1.60	2.56	1.18	0.984

Modelin performansını iyileştirmek için daha fazla veri kaynağı kullanarak modelin girdi çeşitliliğini artırmak, daha uzun süreli verileri dahil etmek, model parametrelerini ayarlamak için farklı hiperparametre optimizasyonları kullanmak gibi potansiyel yollar ele alınabilir. Ayrıca, modelin yanıltıcı tahminler yapması durumunda, yanlış girdi verileri veya anormal verilerin tespiti için filtreleme yöntemleri kullanılabilir.

Sonuç olarak, CNN-BLSTM modelleri, özellikle rüzgâr enerjisi gibi durağan olmayan yapıları yakalama ve elektrik üretimi tahmini gibi sürekli ve dinamik değişkenlere dayalı tahminleme problemleri için etkili bir seçenektir. Önerilen yöntemin, bölgesel yatırımcılara minimum maliyetle, yüksek doğruluk oranında, kullanıcıdan bağımsız ve zaman tasarruflu enerji yönetimi planlamalarında yol haritası olacağı düşünülmektedir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %10

Kaynaklar

- [1] M. Ali, M. Adnan, M.Tariq, Optimum control strategies for short term load forecasting in smart grids. *International Journal of Electrical Power & Energy Systems*, 113, 792-806, 2019. <https://doi.org/10.1016/j.ijepes.2019.06.010>.
- [2] C. Wang, T. Bäck, H. H. Hoos, M. Baratchi, S. Limmer, and M. Olhofer, Automated machine learning for short-term electric load forecasting. In 2019 IEEE Symposium Series on Computational Intelligence SSCI, pp. 314-321, Xiamen, China, December 2019.
- [3] S. Bouktif, A. Fiaz, A. Ouni, M. A. Serhani, Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches. *Energies*, 11(7), 1636, 2018. <https://doi.org/10.3390/en11071636>.
- [4] J. Wu, X. Y. Chen, H. Zhang, L. D. Xiong, H. Lei, S. H. Deng, Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*, 17(1), 26-40, 2019. <https://doi.org/10.11989/JEST.1674-862X.80904120>.
- [5] Y. Wang, S. Sun, X. Chen, X. Zeng, Y. Kong, J. Chen, T. Wang, Short-term load forecasting of industrial customers based on SVM and XGBoost. *International Journal of Electrical Power & Energy Systems*, 129, 106830, 2021. <https://doi.org/10.1016/j.ijepes.2021.106830>.
- [6] K. Liu, J. Cheng, J. Yi, Copper price forecasted by hybrid neural network with Bayesian Optimization and wavelet transform. *Resources Policy*, 75, 102520, 2022. <https://doi.org/10.1016/j.resourpol.2021.102520>.
- [7] D. M. Belete and M. D. Huchaiiah, Grid search in hyperparameter optimization of machine learning models for prediction of HIV/AIDS test results. *International Journal of Computers and Applications*, 44(9), 875-886, 2022. <https://doi.org/10.1080/1206212X.2021.1974663>.
- [8] H. Alibrahim and S. A. Ludwig, Hyperparameter optimization: Comparing genetic algorithm against grid search and bayesian optimization. In 2021 IEEE Congress on Evolutionary Computation, pp. 1551-1559, Kraków, Poland, June 2021.
- [9] B. Z. Aufa, S. Suyanto and A. Arifianto, Hyperparameter setting of LSTM-based language model using grey wolf optimizer. In 2020 International Conference on Data Science and Its Applications, pp. 1-5, Bandung, Indonesia, August, 2020.
- [10] A. Zainab, A. Ghayeb, M. Houchati, S. S. Refaat and H. Abu-Rub, Performance evaluation of tree-based models for big data load forecasting using randomized hyperparameter tuning. In 2020 IEEE International Conference on Big Data, pp. 5332-5339, Atlanta, GA, USA, December, 2020.
- [11] S. Gao, Y. Huang, S. Zhang, J. Han, G. Wang, M. Zhang, Q. Lin, Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. *Journal of Hydrology*, 589, 125188, 2020. <https://doi.org/10.1016/j.jhydrol.2020.125188>.
- [12] S. M. J. Jalali, S. Ahmadian, A. Khosravi, M. Shafiekhah, S. Nahavandi, J. P. Catalão, A novel evolutionary-based deep convolutional neural network model for intelligent load forecasting. *IEEE Transactions on Industrial Informatics*, 17(12), 8243-8253, 2021. <https://doi.org/10.1109/TII.2021.3065718>.
- [13] G. Trierweiler Ribeiro, J. Guilherme Sauer, N. Fraccanabba, V. Cocco Mariani, L. dos Santos Coelho, Bayesian optimized echo state network applied to short-term load forecasting. *Energies*, 13(9), 2390, 2020. <https://doi.org/10.3390/en13092390>.
- [14] F. Kosanoğlu, Z. N. Kiriş ve Ö. F. Beyca, Tekrarlayan Sinir Ağları Temelli Rüzgâr Hızı Tahmin Modelleri: Yalova Bölgesinde Bir Uygulama. *Journal of Intelligent Systems: Theory and Applications*, 5(2), 178-188, 2022. <https://doi.org/10.38016/jista.1120383>.
- [15] A. Gülcü ve Z. Kuş, A Survey of Hyper-parameter Optimization Methods in Convolutional Neural Networks. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 7(2), 503-522, 2019. <https://doi.org/10.29109/gujsc.514483>.
- [16] P. Görgel ve E. Kavlak, Uzun kısa süreli hafıza ve evrimsel sinir ağları ile rüzgâr enerjisi üretim tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11(1), 69-80, 2020. <https://doi.org/10.24012/dumf.596533>.
- [17] Y. Yu, X. Si, C. Hu, J. Zhang, A review of recurrent neural networks: LSTM cells and network architectures. *Neural Computation*, 31(7), 1235-1270, 2019. https://doi.org/10.1162/neco_a_01199.
- [18] V. Pattana-Anake and F. J. J. Joseph, Hyper Parameter Optimization of Stack LSTM Based Regression for PM 2.5 Data in Bangkok. In 2022 7th International

- Conference on Business and Industrial Research, pp. 13-17, Bangkok, Thailand, May 2022.
- [19] L. Latifoğlu, Derin sinir ağları modeli ile standardize yağış indeksi tahmini. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 1-1, 11(4), 1006-1024, 2022. <https://doi.org/10.28948/ngumuh.1145279>.
- [20] H. Çetiner, Recurrent Neural Network Based Model Development for Energy Consumption Forecasting. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 11(3), 759-769, 2022. <https://doi.org/10.17798/bitlisfen.1077393>.
- [21] Y. Imrana, Y. Xiang, L. Ali, Z. Abdul-Rauf, A bidirectional LSTM deep learning approach for intrusion detection. Expert Systems with Applications, 185, 115524, 2021. <https://doi.org/10.1016/j.eswa.2021.115524>.
- [22] G. Zhang, F. Tan, Y. Wu, Ship motion attitude prediction based on an adaptive dynamic particle swarm optimization algorithm and bidirectional LSTM neural network. IEEE Access, 8, 90087-90098, 2020. <https://doi.org/10.1088/1755-1315/440/3/032115>.
- [23] M. N. Akhter, S. Mekhilef, H. Mokhlis, Z. M. Almohaimed, M. A. Muhammad, A. S. M. Khairuddin, M. M. Hussain, An hour-ahead PV power forecasting method based on an RNN-LSTM model for three different PV plants. Energies, 15(6), 2243, 2022. <https://doi.org/10.3390/en15062243>.
- [24] S. M. Malakouti, A. R. Ghiasi, A. A. Ghavifekr, P. Emami, Predicting wind power generation using machine learning and CNN-LSTM approaches. Wind Engineering, 46(6), 1853-1869, 2022. <https://doi.org/10.1177/0309524X221113013>
- [25] F. Saeed, A. Paul, H. Seo, A Hybrid Channel-Communication-Enabled CNN-LSTM Model for Electricity Load Forecasting. Energies, 15(6), 2263, 2022. <https://doi.org/10.3390/en15062263>.
- [26] A. Rai, A. Shrivastava, K. C. Jana, K. C. A CNN-BiLSTM based deep learning model for mid-term solar radiation prediction. International Transactions on Electrical Energy Systems, 31(9), e12664, 2021. <https://doi.org/10.1002/2050-7038.12664>.
- [27] Y. A. Ali, E. M. Awwad, M. Al-Razgan, A. Maarouf, Hyperparameter Search for Machine Learning Algorithms for Optimizing the Computational Complexity. Processes, 11(2), 349, 2023. <https://doi.org/10.3390/pr11020349>.
- [28] Z. Qu, J. Xu, Z. Wang, R. Chi, H. Liu, Prediction of electricity generation from a combined cycle power plant based on a stacking ensemble and its hyperparameter optimization with a grid-search method. Energy, 227, 120309, 2021. <https://doi.org/10.1016/j.energy.2021.120309>.
- [29] E. Akarslan and F. O. Hocaoglu, A novel method based on similarity for hourly solar irradiance forecasting. Renewable Energy, 112, 337-346, 2017. <https://doi.org/10.1016/j.renene.2017.05.058>.
- [30] R. Jiao, T. Zhang, Y. Jiang, H. He, Short-term non-residential load forecasting based on multiple sequences LSTM recurrent neural network. IEEE Access, 6, 59438-59448, 2018. <https://doi.org/10.1109/ACCESS.2018.2873712>.
- [31] E. Tanyıldız and F. Demirtaş, Hyper Parameter Optimization. In 2019 1st International Informatics and Software Engineering Conference, pp. 1-5, Ankara, Turkey, November, 2019.

