



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



Rüzgâr enerji santral üretim tahmininde kullanılan meteorolojik veriler için en uygun içsel mod fonksiyonunun belirlenmesi: İzmir örneği

Determination of the most appropriate intrinsic mode function for meteorological data used in wind power plant generation forecasting: The case of İzmir

Yazar(lar) (Author(s)): İsrail KARADÖL¹

ORCID¹: 0000-0002-9239-0565

To cite to this article: Karadöl İ., “Rüzgâr Enerji Santral Üretim Tahmininde Kullanılan Meteorolojik Veriler için En Uygun İçsel Mod Fonksiyonunun Belirlenmesi: İzmir Örneği”, *Journal of Polytechnic*, 28(6): 1593-1602, (2025).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Karadöl İ., “Rüzgâr Enerji Santral Üretim Tahmininde Kullanılan Meteorolojik Veriler için En Uygun İçsel Mod Fonksiyonunun Belirlenmesi: İzmir Örneği”, *Politeknik Dergisi*, 28(6): 1593-1602, (2025).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1636813

Rüzgâr Enerji Santral Üretim Tahmininde Kullanılan Meteorolojik Veriler için En Uygun İçsel Mod Fonksiyonunun Belirlenmesi: İzmir Örneği


Determination of the Most Appropriate Intrinsic Mode Function for Meteorological Data Used in Wind Power Plant Generation Forecasting: The Case of İzmir

Önemli noktalar (Highlights)

- ❖ Rüzgâr Enerji Santrali (RES) üretim tahmininde kullanılan meteorolojik veriler için en uygun içsel mod fonksiyonlarının belirlenmesi (Determination of optimal intrinsic mode functions for meteorological data used in Wind Power Plant (WPP) generation forecasting)
- ❖ Tüm içsel mod fonksiyonlarının uzun kısa-dönem bellek (LSTM) modeli tahmin sonuçlarının farklı performans metrikleri ile incelenmesi (Tüm içsel mod fonksiyonlarının uzun kısa-dönem bellek (LSTM) modeli tahmin sonuçlarının farklı performans metrikleri ile incelenmesi)

Grafik Özet (Graphical Abstract)

Bu çalışma da rüzgâr enerji santral (RES) üretimlerinin uzun kısa-dönem bellek (LSTM) modeli girişi parametreleri olarak kullanılan meteorolojik veriler için en uygun içsel mod fonksiyonlarının belirlenmesine yönelik bir araştırma gerçekleştirilmiştir./ In this study, an investigation was carried out to determine the most appropriate intrinsic mode functions for meteorological data used as input parameters for the long short-term memory (LSTM) model of wind power plant (WPP) generation.



Şekil. Akış diyagramı /Figure. Flow diagram

Amaç (Aim)

RES üretim tahmininde kullanılan meteorolojik veriler için en uygun içsel mod fonksiyonunun (İMF) belirlenmesi. / Determination of the optimal intrinsic mode function for meteorological data used in WPP generation forecasting .

Tasarım ve Yöntem (Design & Methodology)

Ampirik mod ayrıştırma ve LSTM modeli kullanılmıştır./ Empirical mode decomposition and LSTM model are used.

Özgünlük (Originality)

LSTM modelini de giriş veri seti olarak kullanılan meteorolojik verilere ait en uygun İMF sinyalinin belirlenmesine yönelik çalışma bulunmadığı için özgündür. / The LSTM model is also unique as there is no study to determine the most appropriate IMF signal for the meteorological data used as input data set.

Bulgular (Findings)

İzmir ili meteorolojik verilere göre, LSTM modeli ile tesis üretim tahmini için en uygun İMF1-İMF5 sinyali olduğu gösterilmiştir. / According to the meteorological data of İzmir province, it is shown that the most suitable IMF1-İMF5 signal for plant production forecasting with the LSTM model.

Sonuç (Conclusion)

İMF1-İMF5 giriş verilerine göre MAE, MSE, RMSE ve R2 performans metrikleri sırasıyla 0.079, 0.014, 0.119 ve 0.848 olarak hesaplanmıştır. / According to the input data of IMF1-İMF5, the performance metrics of MAE, MSE, RMSE, and R2 are calculated as 0.079, 0.014, 0.119, and 0.848, respectively.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Rüzgâr Enerji Santral Üretim Tahmininde Kullanılan Meteorolojik Veriler için En Uygun İçsel Mod Fonksiyonunun Belirlenmesi: İzmir Örneği

Araştırma Makalesi / Research Article

İsrafil KARADÖL^{1*}

¹Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Kilis 7 Aralık Üniversitesi, Türkiye
(Geliş/Received : 10.02.2025 ; Kabul/Accepted : 18.03.2025 ; Erken Görünüm/Early View : 03.04.2025)

ÖZ

Yapılan bu çalışmanın amacı rüzgâr enerji santral (RES) üretimlerinin uzun kısa dönem bellek (LSTM) modeli girişi parametreleri olarak kullanılan meteorolojik veriler için en uygun içsel mod fonksiyonlarının belirlenmesidir. Bu amaçla ilk olarak İzmir ilinin 2022 yılı meteorolojik verileri ve RES üretim verileri elde edilmiştir. Elde edilen meteorolojik veriler Ampirik Mod Ayrıştırma metodu kullanılarak 8 farklı içsel mod fonksiyonuna (İMF) dönüştürülmüştür. 8 farklı meteorolojik İMF'ler LSTM modelinde giriş olarak kullanılarak 2 saat sonraki RES üretimlerinin tahmin edilmesi amaçlanmıştır. LSTM modeli ile elde edilen RES üretim tahminlerinin performansını değerlendirmek amacıyla regresyon analizi (R2), ortalama mutlak hata (MAE), ortalama karesel hata (MSE) ve ortalama karesel hata kökü (RMSE) metrikleri kullanılmıştır. Bu metriklere göre test veri seti ile LSTM modeli kullanılarak en iyi RES üretim tahmini İMF1-İMF5 içsel mod fonksiyonun da gerçekleştirilmiştir. İMF1-İMF5 giriş verilerine göre MAE, MSE, RMSE ve R2 performans metrikleri sırasıyla 0.079, 0.014, 0.119 ve 0.848 olarak hesaplanmıştır. Test veri seti üzerinden ham veri ile İMF1-İMF5 arasındaki MAE, MSE, RMSE ve R2 performans metriklerini karşılaştırdığımızda, ham veriye göre MAE, MSE ve RMSE metrikleri sırasıyla %56, %74 ve %49 azalmıştır. R2 ise %204 artmıştır. Elde edilen tüm bu sonuçlar meteorolojik veriler ile LSTM ağ mimarisinde RES üretim tahmini için en uygun içsel mod fonksiyonunun İMF1-İMF5 olduğunu göstermektedir.

Anahtar Kelimeler: Rüzgâr Enerji Santrali, Uzun Kısa Dönem Bellek, Ampirik Mod Ayrıştırma, İçsel Mod Fonksiyonu.

Determination of the Most Appropriate Intrinsic Mode Function for Meteorological Data Used in Wind Power Plant Generation Forecasting: The Case of İzmir

ABSTRACT

This study aims to determine the most appropriate intrinsic mode functions for meteorological data used as input parameters of the Long Short Term Memory (LSTM) model of wind power plant (WPP) generation. For this purpose, meteorological data and WPP generation data for the year 2022 of İzmir province were obtained. The obtained meteorological data were transformed into 8 different intrinsic mode functions (IMF) using the Empirical Mode Decomposition method. 8 different meteorological IMF's are input to the LSTM model to predict the RES generation 2 hours ahead. Regression analysis (R2), mean absolute error (MAE), mean squared error (MSE), and root mean squared error (RMSE) metrics were used to evaluate the performance of the RES generation forecasts obtained with the LSTM model. According to these metrics, the best RES generation prediction using the LSTM model with the test data set was determined in the IMF1-IMF5 internal mode function. According to the input data of IMF1-IMF5, the performance metrics of MAE, MSE, RMSE, and R2 are calculated as 0.079, 0.014, 0.119, and 0.848, respectively. When we compare the MAE, MSE, RMSE, and R2 performance metrics between raw data and IMF1-IMF5 over the test data set, the MAE, MSE, and RMSE metrics decreased by 56%, 74%, and 49% respectively compared to the raw data. R2 increased by 204%. All these results show that IMF1-IMF5 is the most suitable IMF for RES generation forecasting in LSTM network architecture with meteorological data.

Keywords: Wind Power Plant, Long Short Term Memory, Empirical Mode Decomposition, Intrinsic Mode Function.

1. GİRİŞ (INTRODUCTION)

Dünya nüfusunun sürekli artış göstermesi ve bu durumun doğal sonucu olarak enerji talebi her geçen gün artmaktadır. Artan enerji talebinin temiz ve sürdürülebilir enerji kaynaklarından karşılanması büyük son yıllarda önem arz etmektedir. Bu doğrultuda yenilenebilir enerji kaynaklarına yönelim son yıllarda büyük artış göstermiştir. Yenilenebilir enerji kaynakları arasında

RES ön plana çıkmaktadır. Fakat bu kaynakların rastgele üretim karakteristiğinden dolayı RES üretimleri şebeke esnekliğini ve güvenliğini olumsuz etkilemektedir. RES üretimlerinde görülen ani yükselmelere karşı şebekeyi korumak amacıyla şebeke işletmecisi ya yük atmakta ya da çalışmakta olan santralleri devre dışı bırakmak zorunda kalmaktadır. Ters durumda yani RES üretimlerindeki ani düşüşleri karşılamak için ise şebeke

*Sorumlu Yazar (Corresponding Author)
e-posta : israfilkaradol@kilis.edu.tr

işletmecisi yeni tesisleri devreye almak zorundadır [1]. Bu iki durum da şebeke işletmecisi açısından ek maliyet oluşturmaktadır [2]. Şebeke işletmesinde ortaya çıkan bu ek maliyeti gidermek amacıyla araştırmacılar yapay zeka tabanlı sistemler ile ileri yönlü (1 saat, 2 saat,..., 24 saat, vb.) tahmin yöntemleri kullanarak RES üretimlerini veya rüzgâr hızlarını tahmin etmeye yönelmişleridir [2].

Bu alanda yapılan araştırmaları incelediğimizde: Saxena ve ark., farklı yüksekliklerdeki deniz üstü rüzgâr hızlarını tahmin etmek için evrişimli sinir ağı (CNN), yığılmış LSTM, çift yönlü LSTM, CNN-LSTM, çok katmanlı algılayıcı ve iki boyutlu evrişimli LSTM tabanlı derin öğrenme modellerini kullanmışlardır. Bu çalışma sonucunda en iyi tahmin performansı çift yönlü LSTM modelinde elde edilmiştir [3]. Kaysal ve ark., RES üretimini belirlemek amacıyla derin öğrenme metodlarından CNN ve Çift Yönlü LSTM mimarilerini hibrit bir şekilde kullanmışlardır [4]. Önerilen yöntem ile R²'yi 0.984 olarak hesaplamışlardır [4]. Benzer şekilde farklı derin öğrenme yöntemleri ile birçok araştırma yapılmıştır[5]–[7]. Fakat ilerleyen araştırmalarda meteoroloji verileri veya RES üretim verileri ile tahmin doğruluğunu arttırmak amacıyla ampirik mod ayrıştırma metodu kullanarak veriler ön işleme sürecine tabi tutulmuştur. Wang ve ark. RES üretimlerini tahmin edebilmek amacıyla giriş veri setini ampirik mod ayrıştırma (AMA) metodu ile içsel mod fonksiyonlarına dönüştürmüşlerdir. Daha sonra elde edilen İMF'lere temel bileşen analizi uygulanarak farklı derin öğrenme yöntemleriyle RES üretim tahmini yapılmıştır [8]. Zhang ve ark., meteorolojik verileri 7 İMF sinyaline dönüştürmüştür [9]. Elde edilen sinyalleri LSTM modelinde giriş olarak kullanmış ve RES üretim tahmini yapmışlardır [9]. Wang ve ark., benzer bir yöntem kullanarak rüzgâr yön verilerini 9 İMF sinyallerine dönüştürmüş ve rüzgâr yönünü tahmin etmişlerdir [10]. Farklı LSTM metodlarında giriş olarak farklı sayılarda İMF sinyalleri kullanılmıştır [11]–[13]. Fakat yapılan bu çalışmalarda LSTM tabanlı tahmin modelleri için giriş olarak kullanılan meteorolojik verilerin veya RES üretim verilerinin hangi içsel mod fonksiyonunda daha iyi bir tahmin performansı sergilediği konusunda bir belirsizlik vardır.


Literatürdeki bu belirsizliği gidermek amacıyla RES üretim tahmininde kullanılan LSTM modelinin giriş veri seti için en uygun İMF sinyalini araştırılmıştır. Bu amaçla İzmir ilinin 2022 yılına meteorolojik ve RES üretim verileri elde edilmiştir. Elde edilen meteorolojik veriler meteoroloji genel müdürlüğünden, RES üretim verileri ise TEİAŞ Yük Tevzi Müdürlüğünden edinilmiş gerçek zamanlı verilerdir. Veri setleri saatlik çözünürlükte ve 1 yıllık periyodu kapsamaktadır. Daha sonra bu veri setleri 8 farklı İMF sinyallerine ayrıştırılmıştır. Meteorolojik verilere ait her bir İMF sinyal kümesi için LSTM modeli ile RES üretim tahmini yapılmıştır. LSTM modeli ile elde edilen RES üretim tahminlerinin performansını değerlendirmek amacıyla regresyon analizi (R²), ortalama mutlak hata (MAE), ortalama karesel hata (MSE) ve ortalama karesel hata

kökü (RMSE) metrikleri kullanılmıştır. Bu metriklere göre en iyi RES üretim tahmini İMF1-İMF5 içsel mod fonksiyonunun da gerçekleştirilmiştir. Çalışma sonucunda elde edilen bulgular ve sonuçlar alt bölümlerde daha ayrıntılı olarak açıklanmıştır.

2. MATERYAL VE METOD (MATERIAL and METHOD)

2.1. Uygulama (Application)

Yapılan çalışmada ilk olarak meteorolojik veriler ve RES üretim verileri elde edilmiştir. Çalışma kapsamında elde edilen reel verilerin bazı zaman dilimlerinde eksiklikler görülmüştür. Bu eksiklikleri gidermek amacıyla solar radyasyon ve sıcaklık için bir önceki güne ait aynı saatteki veriler kopyalanmıştır. Bu durum solar radyasyon ve sıcaklık verilerinin gün içerisindeki parabolik dağılımından kaynaklanmaktadır. Nem, bulutluluk, yağış miktarı ve rüzgâr verilerinin rastgele dağılımından dolayı, bu veri setlerindeki eksik üretim saatleri tamamlamak amacıyla aynı gün içerisindeki bir önceki saatte ait üretimler kopyalanmıştır. Meteorolojik veriler AMA ile 8 farklı İMF sinyaline ayrıştırılmıştır. Meteorolojik verilerin sinyal özelliklerinden (sinyal yapısından) dolayı daha fazla içsel mod fonksiyonuna ayrıştırılamamıştır. LSTM modeli tahmin sürecinde kullanılan veri seti eğitim, test ve doğrulama olarak bölünmüştür. Meteorolojik verilere ait İMF1 ve kalan sinyaller kullanılarak 2 saat sonraki RES üretimi LSTM modeli ile tahmin edilmiştir. Daha sonra İMF1, İMF2 ve kalan sinyaller kullanılarak 2 saat sonraki RES üretimi LSTM modeli ile tahmin edilmiştir. Bu süreç tüm İMF sinyal kümeleri ve kalan sinyaller kullanılarak (İMF1+kalan1, İMF1+İMF2+kalan2, ..., İMF1+İMF2+...+İMF8+kalan8) ayrı ayrı denenmiştir. Bu denemeler sonucu elde edilen sonuçlar çeşitli performans kriterleri ile değerlendirilmiştir. Yapılan değerlendirmeler sonucunda en iyi performansa sahip İMF ve kalan sinyalleri belirlenmiştir. Yapılan çalışmanın akış diyagramı Şekil 1'de verilmiştir.



Şekil 1. LSTM modeli akış diyagramı (Flow diagram of the LSTM model)

2.2. Ampirik Mod Ayırıştırma Metodu (Empirical Mode Decomposition Method)

Ampirik mod ayırıştırma (AMA) metodu, doğrusal ve durağan olmayan sinyallerin farklı salınım özellikleri gösteren basit alt sinyallerin toplamından oluştuğu mantığına dayanmaktadır [8], [14]. Bu mantığa dayanarak Huang ve arkadaşları tarafından geliştirilen AMA yöntemi ile karmaşık bir sinyal, içsel mod fonksiyonu (Intrinsic Mode Functions, İMF) olarak tanımlanan alt sinyallere ve kalan sinyaline dönüştürülmektedir [15], [16]. Bu amaçla kullanılan matematiksel ifade Eşitlik 1'de verilmiştir.

$$Y_t = \sum_{k=1}^N \dot{I}MF_k + r \quad (1)$$

Verilen bu eşitlikte Y_t giriş sinyalini, N İMF sinyal sayısını ve r kalan sinyali tanımlamaktadır. Bu algorithmada ilk olarak giriş sinyallerinin tüm yerel minimum ve maksimum noktaları belirlenmektedir. Belirlenen yerel maksimum ve minimum noktaları kübik bağlayıcı algoritması ile birleştirilerek üst zarf ($\alpha_{max,1}$) ve alt zarf ($\alpha_{min,1}$) oluşturulur. Üst ve alt zarfın aritmetik ortalaması alınarak ortalama zarf ($\alpha_{ort,1}$) değeri hesaplanır [17], [18]. İlk giriş sinyalinden ortalama zarf serisi çıkarılarak fark serisi (A_1) olarak tanımlanan ilk bileşen bulunur (Eşitlik 2).

$$A_1 = Y_t - \alpha_{ort,1} \quad (2)$$

Hesaplanan fark serisi nispeten durağan bir İMF ise bu fonksiyon İMF1 olarak tanımlanır. Hesaplanan fark serisi nispeten durağan değilse yeni giriş sinyali olarak tanımlanır (A_{11}) ve bir sonraki İMF sinyali hesaplanır (Eşitlik 3).

$$A_{11} = A_1 - \alpha_{ort,11} \quad (3)$$

N defa tekrarlanan bu eleme işlemlerinden sonra fark serisi durağan bir hal aldığı da algoritma sonlandırılır. Ve bu süreç sonunda elde edilen İMF sinyallerinin toplamından giriş sinyali çıkarılarak kalan sinyal (r) hesaplanır [13].

2.3. Performans Değerlendirme Kriterleri (Performance Evaluation Criteria)

Bu bölümde farklı İMF giriş sayılarına göre LSTM modelinin performansını değerlendirmek amacıyla kullanılan metrikler anlatılmaktadır. Bu çalışmada kullanılan performans kriterleri; regresyon analizi (R^2), ortalama mutlak hata (MAE), ortalama karesel hata (MSE) ve ortalama karesel hata köküdür (RMSE). R^2 , tahmin ile gerçek değerler arasındaki benzerliğin büyüklüğünü incelemektedir [16], [19]. MAE ile tahmin ve gerçek değerler arasındaki farkların mutlak değerlerinin ortalaması hesaplanmaktadır [20]. MSE ve RMSE ise sırasıyla tahmin ile gerçek değerler arasındaki farkların karesinin ortalamasını ve farkların karesinin ortalamasının karekökünü tanımlamaktadır [21]. Performans kriterlerinden R^2 'nin büyüklüğü ile tahmin doğruluğu paralellik göstermektedir. MAE, MSE ve

RMSE büyüklükleri arttıkça, tahmin doğruluğu ise azalmaktadır. Çalışmada kullanılan performans değerlendirme kriterlerinin matematiksel ifadeleri Eşitlik 4,5,6,7'de gösterilmektedir [3]. Eşitlik 4,5,6,7'de verilen n , $y_i(t)$, $x_i(t)$, $\hat{y}_i(t)$ ve $\hat{x}_i(t)$ sırasıyla gözlem sayısını, i anındaki tahmin değerini, i anındaki gerçek değeri, tahmin değerlerinin ortalamasını ve gerçek değerlerin ortalamasını göstermektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i(t) - \hat{y}_i(t))^2}{\sum_{i=1}^n (y_i(t) - \bar{x}_i(t))^2} \quad (4)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i(t) - x_i(t)| \quad (5)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i(t) - x_i(t))^2 \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i(t) - x_i(t))^2} \quad (7)$$

2.4. Uzun-Kısa Dönem Bellek (Long Short Term Memory - LSTM)

Tekrarlayan sinir ağları (RNN) kısa süreli bağımlı problemlerin çözülmesinde yaygın olarak kullanılmaktadır. Fakat uzun süreli bağımlı problemlerin çözüm sürecinde gradyan patlaması ve gradyan kaybolması sorunları ortaya çıkmaktadır [22]. Ortaya çıkan bu sorunların üstesinden gelmek amacıyla Uzun-Kısa Dönem Bellek (LSTM) olarak tanımlanan özel bir sinir ağı geliştirilmiştir. Geliştirilen bu sinir ağı, RNN açısından farklı olarak her biri mantıksal kontrol birimi olarak tanımlanan üç kapı (unutma, giriş ve çıkış kapısı) içermesidir. Bu mantıksal kapı yapısı sayesinde, LSTM'nin zaman serilerindeki bazı gecikme ve aralık durumlarını daha iyi ele alması sağlanır [10], [23]. Ayrıca bu özellik sayesinde kısa ve uzun süreli bağımlı problemlerde daha iyi performans sergiler. Temel LSTM mimarisi Şekil 2'de verilmiştir.



Şekil 2. Temel LSTM mimarisi (Basic LSTM architecture)

Şekilde verilen LSTM hücresindeki, c_{t-1} ve c_t sırasıyla geçmişteki hücre durumunu ve yeni hücre durumunu tanımlamaktadır. Hücre durumu (bellek), kapı yapısı sayesinde bilgileri filtreleyerek hangi bilgilerin silineceğini veya hangi bilgilerin hafızaya alınacağını belirleyen yapıdır [24]. h_{t-1} ve h_t ise sırasıyla $t-1$ ve t anındaki gizli durum bilgilerini tanımlamaktadır [22]. x_t ise t anındaki girişi tanımlamaktadır. LSTM modelinin çalışma metodu aşağıda adım adım ve matematiksel olarak açıklanmıştır. Birinci adımda unutma kapısı vasıtasıyla hangi bilgilerin yok olacağına karar verilir. Bu karar Eşitlik 8'de f_t fonksiyonu olarak gösterilen unutma

kapısındaki σ (sigmoid) katmanı aracılığıyla yapılır. Bu kapı h_{t-1} ve x_t girişleri için 0 ile 1 aralığında çıkış verir. f_t fonksiyonu sadece c_t 'nin ihtiyaç duyduğu bilgileri kaydeder.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (8)$$

İkinci adımda bellek biriminde depolanacak yeni bilgiler belirlenir. Depolanacak bilgileri belirlemek amacıyla giriş kapısındaki σ katmanı kullanılır (Eşitlik 9).

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (9)$$

Üçüncü adımda tanh katmanı kullanılarak yeni aday değer C_t üretilir (Eşitlik 10) ve hücre durumuna eklenir. Daha sonra istenmeyen bilgileri unutmak amacıyla eski hücre durumu ile f_t çarpılır ve yeni aday değer ile i_t çarpılarak Eşitlik 11'de verilen c_t elde edilir.

$$C_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (10)$$

$$c_t = c_{t-1}f_t + i_tC_t \quad (11)$$

Dördüncü adımda çıkış kapısındaki bilgi çıkışını belirlemek amacıyla σ katmanı kullanılarak o_t elde edilir (Eşitlik 12). Daha sonra c_t tanh katmanında değerlendirilerek $[-1,1]$ aralığında ölçeklendirilir. Ölçeklendirme sonucunda elde edilen sayı ile çıkış kapısındaki bilgi çarpılarak h_t elde edilir (Eşitlik 13).

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (12)$$

$$h_t = o_t \tanh(c_t) \quad (13)$$

Yapılan çalışmada kullanılan LSTM modeline ait parametreler Çizelge 1'de verilmiştir. Çizelgede verilen parametreleri belirlemek amacıyla Hiperparametre optimizasyonu yapılmıştır. Bu optimizasyon modelinde RandomSearch kullanılarak en iyi model parametreleri belirlenmiştir. Öğrenme oranı arama uzayı minimum, maksimum ve adım değerleri sırasıyla $1e^{-4}$, $1e^{-2}$ ve log olarak belirlenmiştir. LSTM modeli nöron sayısı arama uzayı minimum, maksimum ve adım değerleri sırasıyla 32, 512 ve 32 olarak belirlenmiştir.

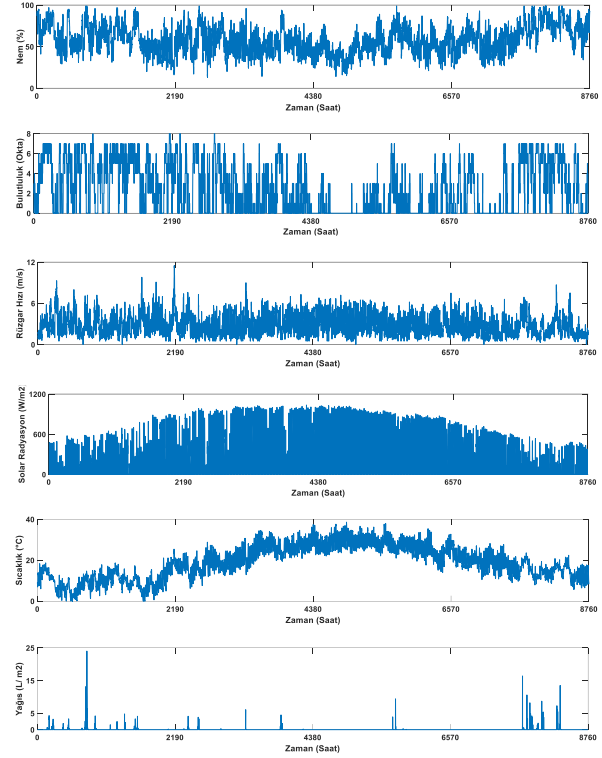
Çizelge 1. LSTM modelinin parametreleri (Parameters of the LSTM model)

Parametreler	Parametre Değerleri
Gizli katman sayısı	2
LSTM modeli nöron sayısı	320
Aktivasyon fonksiyonu	ReLU
Optimizasyon yöntemi	Adam
Öğrenme oranı	0.0005

2.5. Meteorolojik Veriler (Meteorological Data)

Yapılan çalışmada ileri yönlü tahmin gerçekleştirmek amacıyla kullanılan meteorolojik veriler solar radyasyon, nem, bulutluluk, rüzgâr ve sıcaklıktır. Tüm veriler saatlik çözünürlükte ve 8760 adettir. Veriler 01.01.2022-31.12.2022 tarih aralığında gerçekleşen meteorolojik olayları içermektedir. Bu veriler Türkiye Meteoroloji Genel Müdürlüğünden temin edilmiş olup İzmir iline ait gerçek zamanlı verilerdir. Çalışma kapsamında elde edilen verilerin bazı zaman dilimlerinde eksiklikler


görülmüştür. Bu eksiklikleri gidermek amacıyla solar radyasyon ve sıcaklık için bir önceki güne ait aynı saatteki veriler kopyalanmıştır. Bu durum solar radyasyon ve sıcaklık verilerinin gün içerisindeki parabolik dağılımından kaynaklanmaktadır. Nem, bulutluluk, yağış miktarı ve rüzgâr verilerinin rastgele dağılımından dolayı, bu veri setlerindeki eksik üretim saatleri tamamlamak amacıyla aynı gün içerisindeki bir önceki saatte ait üretimler kopyalanmıştır. Bu sayede elde edilen meteorolojik veriler Şekil 3'te gösterilmiştir.



Şekil 3. İzmir meteorolojik verileri (Meteorological data of Izmir)

2.6. Rüzgâr Santrali Üretim ve Teknik Verileri (Wind Power Generation and Technical Data)

Yapılan çalışmada İzmir il sınırları içerisinde yer alan rüzgâr enerji santralının 2 saat sonraki üretimini tahmin etmek amacıyla gerçek tesis üretimleri kullanılmıştır. Gerçek tesis üretimleri yük tevzi genel müdürlüğünden elde edilmiştir. Elde edilen veri seti 01.01.2022-31.12.2022 tarihlerini kapsamakta ve saatlik çözünürlüktedir. Çalışmada kullanılan tesis İzmir il sınırları içerisinde yer almakta ve 19.8 MW kurulu güce sahiptir. Tesiste Vestas marka 6 adet türbin bulunmaktadır. Her bir türbin 3,3 MW enerji üretim kapasitesine sahiptir. Bu tesis üretime ait bazı istatistiksel bilgiler Çizelge 2'de verilmiştir. Ayrıca tesis üretimi Şekil 4'te verilmiştir.



Şekil 4. İzmir rüzgâr santrali enerji üretimi (Izmir wind power plant energy generation)

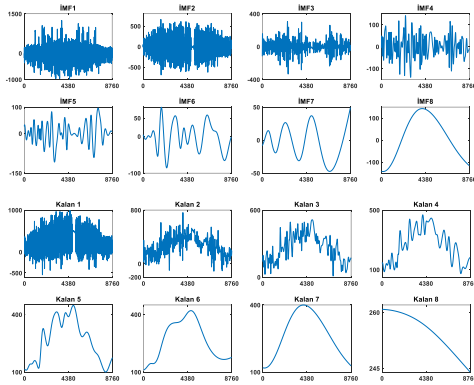
Çizelge 2. RES istatistiksel özellikleri (Statistical properties of WPP)

Maksimum üretim	19.69 MWh
Minimum üretim	0 MWh
Ortalama üretim	5.90 MWh
Üretim standart sapması	6.15 MWh
Kurulu güç	19.80 MW
Zaman	01.01.2022-31.12.2022
Çözünürlük	1 Saat

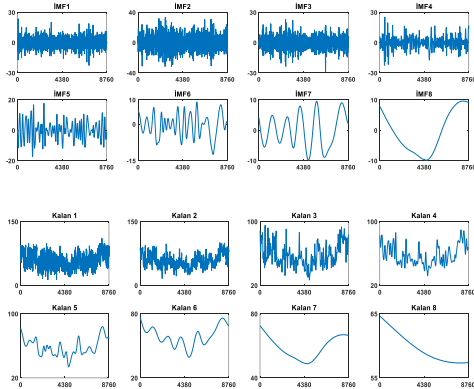
3. BULGULAR (RESULTS)

3.1. Meteorolojik Verilerin Ampirik Moda Ayrıştırılması (Empirical Mode Decomposition of Meteorological Data)

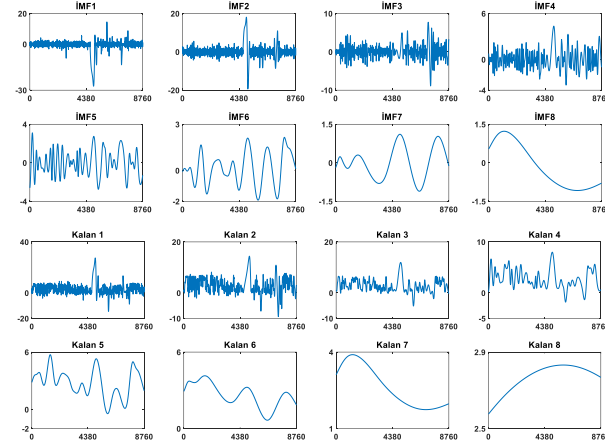
İzmir ilinin meteorolojik verileri kullanılarak 2 saat sonraki RES üretimini tahmin edebilmek için LSTM modeli kullanılmıştır. Kullanılan LSTM modelinin genel tahmin doğruluğunu artırmak amacıyla meteorolojik veriler (solar radyasyon, rüzgar hızı, bulutluluk, nem, sıcaklık ve yağış miktarı) ampirik mod ayrıştırma tekniği ile çeşitli düşük ve yüksek frekanslı bileşenlere ayrıştırılmıştır. Meteorolojik verilere ait ayrıştırma sonuçları Şekil 5, 6, 7, 8, 9, 10'da gösterilmiştir. Tüm veriler 8 İMF sinyaline ayrıştırılmıştır. Her bir ayrıştırma basamağında elde edilen kalan sinyaller Şekil 4-9'da gösterilmiştir.



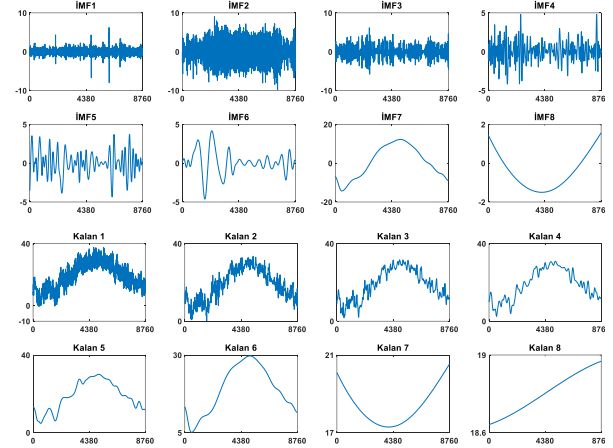
Şekil 5. AMA kullanılarak solar radyasyon verilerinin zaman serisi ayrıştırılması (Time series decomposition of solar radiation data using EMD)



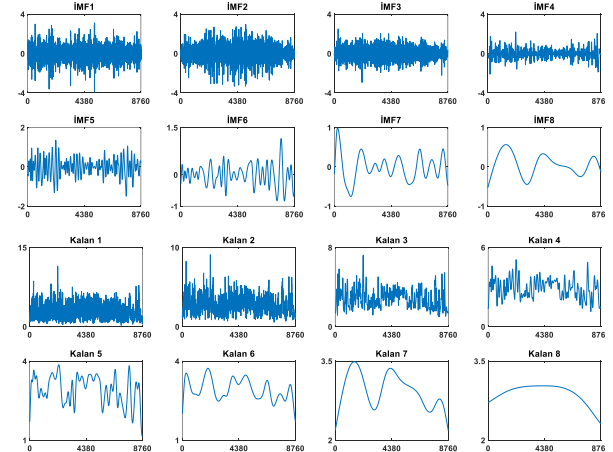
Şekil 6. AMA kullanılarak nem verilerinin zaman serisi ayrıştırılması (Time series decomposition of humidity data using EMD)



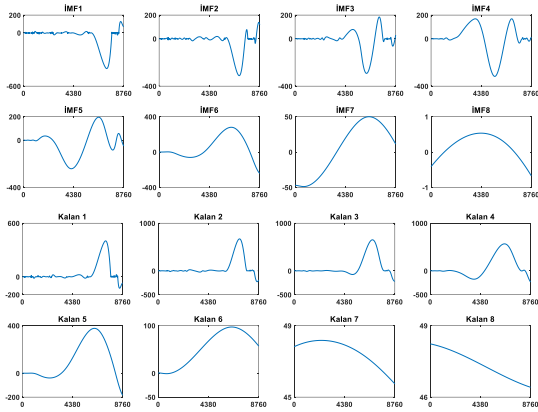
Şekil 7. AMA kullanılarak bulutluluk verilerinin zaman serisi ayrıştırılması (Time series decomposition of cloudiness data using EMD)



Şekil 8. AMA kullanılarak sıcaklık verilerinin zaman serisi ayrıştırılması (Time series decomposition of temperature data using EMD)




Şekil 9. AMA kullanılarak rüzgar hızı verilerinin zaman serisi ayrıştırılması (Time series decomposition of wind speed data using EMD)



Şekil 10. AMA kullanılarak yağış miktarı verilerinin zaman serisi ayrıştırılması (Time series decomposition of rainfall amount data using EMD)

3.2. Farklı İçsel Mod Fonksiyonlarına Göre LSTM Performansları (LSTM Performances According to Different Intrinsic Mode Functions)

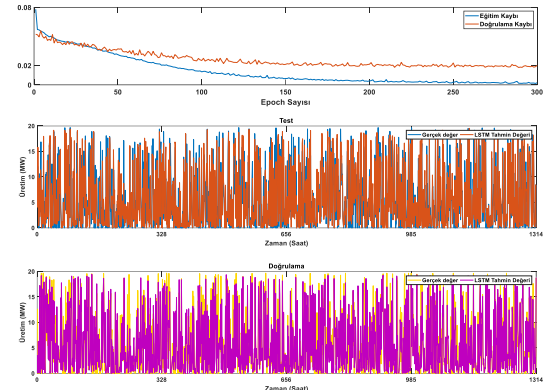
Yapılan çalışmada farklı meteorolojik İMF sinyallerine göre LSTM performansı incelenmiştir. Bu inceleme için kullanılan LSTM modelinde kayıp olarak ortalama karesel hata (MSE) dikkate alınmıştır. LSTM performansına bakmak amacıyla ilk olarak meteorolojik verilere ait İMF1 ve kalan 1 sinyalleri (12x8760 adet veri) giriş olarak kullanılmıştır. Bu giriş sinyallerine göre 300 epoch için eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 11’de gösterilmiştir. Eğitim ve doğrulama kayıplarının minimum değerleri sırasıyla 0.0014 ve 0.0357 olarak hesaplanmıştır. Bu giriş verilerine göre minimum eğitim ve doğrulama kayıpları arasındaki fark 0.0343’tür. Eğitim ve doğrulama kaybı arasındaki fark 47 epochtan sonra ayrışma göstermiş ve bu veri kümesine göre LSTM modeli kötü bir performans göstermiştir. Gösterilen bu kötü performans test ve doğrulama verilerine ait şekilde daha net görülmektedir.



Şekil 11. Eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses, test and validation data for true value and LSTM predicted values)

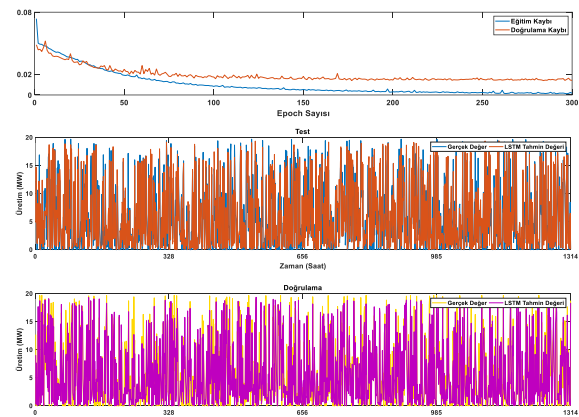
Meteorolojik verilere ait İMF1, İMF2 ve Kalan2 sinyalleri (18x8760 adet veri) giriş olarak kullanıldığında LSTM modeline ait eğitim ve doğrulama

kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 12’de gösterilmiştir. Bu giriş verilerine göre eğitim ve doğrulama kayıplarının minimum değerleri sırasıyla 0.0014 ve 0.0179 olarak hesaplanmıştır. Bu giriş verilerine göre minimum eğitim ve doğrulama kayıpları arasındaki fark 0.0165’dir. Eğitim ve doğrulama kaybı arasındaki fark 45 epochtan sonra ayrışma göstermiş ve bu veri kümesine göre LSTM modeli kötü bir performans göstermiştir. Gösterilen bu kötü performans test ve doğrulama verilerine ait şekilde daha net görülmektedir.



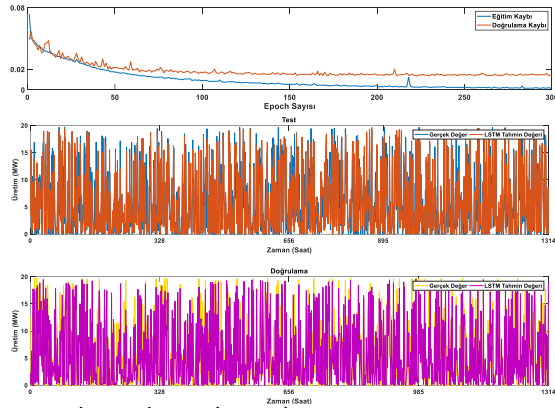
Şekil 12. İMF1, İMF2 ve Kalan2 için eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses for IMF1, IMF2 and Remainder2, test and validation data for true value and LSTM prediction values)

Meteorolojik verilere ait İMF1, İMF2, İMF3 ve Kalan3 sinyalleri (24x8760 adet veri) giriş olarak kullanıldığında LSTM modeline ait eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 13’te gösterilmiştir. Bu giriş verilerine göre eğitim ve doğrulama kayıplarının minimum değerleri sırasıyla 0.0012 ve 0.0138 olarak hesaplanmıştır. Bu giriş verilerine göre minimum eğitim ve doğrulama kayıpları arasındaki fark 0.0126’dır. Eğitim ve doğrulama kaybı arasındaki fark 45 epochtan sonra ayrışma göstermiştir.



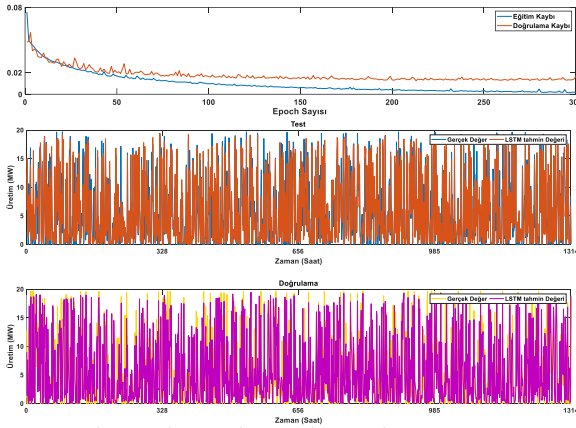
Şekil 13. İMF1, İMF2, İMF3 ve Kalan3 için eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses for IMF1, IMF2, IMF3 and Remainder3, test and validation data for true value and LSTM prediction values)

Meteorolojik verilere ait İMF1, İMF2, İMF3, İMF4 ve Kalan4 sinyalleri (30x8760 adet veri) giriş olarak kullanıldığında LSTM modeline ait eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 14'te gösterilmiştir. Bu giriş verilerine göre eğitim ve doğrulama kayıplarının minimum değerleri sırasıyla 0.0013 ve 0.0133 olarak hesaplanmıştır. Bu giriş verilerine göre minimum eğitim ve doğrulama kayıpları arasındaki fark 0.0120'dir. Eğitim ve doğrulama kaybı arasındaki fark 26 epochtan sonra ayrışma göstermiştir.



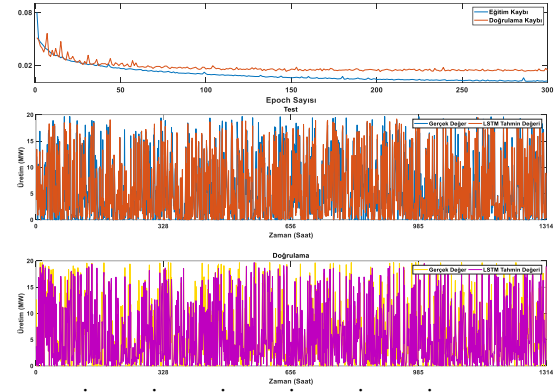
Şekil 14. İMF1, İMF2, İMF3, İMF4 ve Kalan4 için eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses for IMF1, IMF2, IMF3, IMF4 and Remainder4, test and validation data for true value and LSTM prediction values)

Meteorolojik verilere ait İMF1, İMF2, İMF3, İMF4, İMF5 ve Kalan5 sinyalleri (36x8760 adet veri) giriş olarak kullanıldığında LSTM modeline ait eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 15'te gösterilmiştir. Bu giriş verilerine göre eğitim ve doğrulama kayıplarının minimum değerleri sırasıyla 0.0014 ve 0.0124 olarak hesaplanmıştır. Bu giriş verilerine göre minimum eğitim ve doğrulama kayıpları arasındaki fark 0.0107'dir. Eğitim ve doğrulama kaybı arasındaki fark 25 epochtan sonra ayrışma göstermiştir.



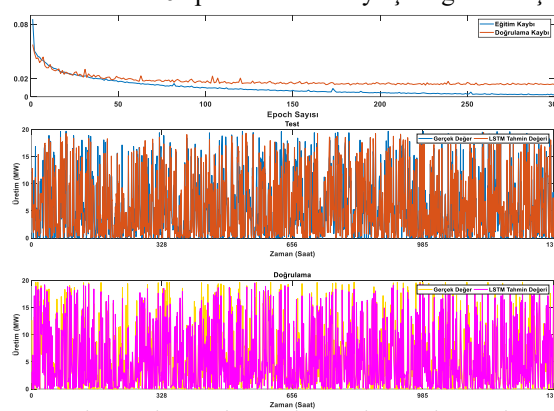
Şekil 15. İMF1, İMF2, İMF3, İMF4, İMF5 ve Kalan5 için eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses for IMF1, IMF2, IMF3, IMF4, IMF5 and Remainder5, test and validation data for true value and LSTM prediction values)

Meteorolojik verilere ait İMF1, İMF2, İMF3, İMF4, İMF5, İMF6 ve Kalan6 sinyalleri (42x8760 adet veri) giriş olarak kullanıldığında LSTM modeline ait eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 16'da gösterilmiştir. Bu giriş verilerine göre eğitim ve doğrulama kayıplarının minimum değerleri sırasıyla 0.0016 ve 0.0127 olarak hesaplanmıştır. Bu giriş verilerine göre minimum eğitim ve doğrulama kayıpları arasındaki fark 0.0111'dir. Eğitim ve doğrulama kaybı arasındaki fark 37 epochtan sonra ayrışma göstermiştir.



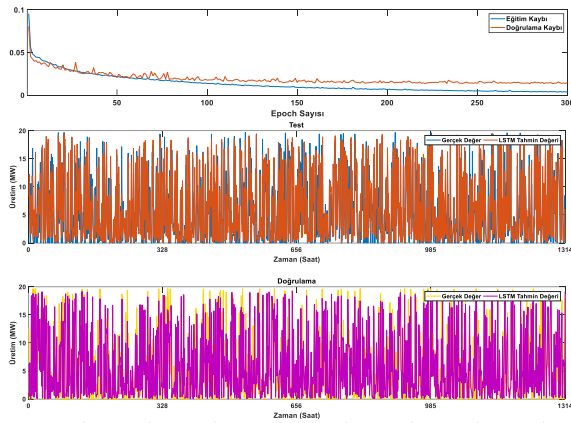
Şekil 16. İMF1, İMF2, İMF3, İMF4, İMF5, İMF6 ve Kalan6 için eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses for IMF1, IMF2, IMF3, IMF4, IMF5, IMF6 and Remainder6, test and validation data for true value and LSTM prediction values)

Meteorolojik verilere ait İMF1, İMF2, İMF3, İMF4, İMF5, İMF6, İMF7 ve Kalan7 sinyalleri (48x8760 adet veri) giriş olarak kullanıldığında LSTM modeline ait eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 17'de gösterilmiştir. Bu giriş verilerine göre eğitim ve doğrulama kayıplarının minimum değerleri sırasıyla 0.0021 ve 0.0128 olarak hesaplanmıştır. Bu giriş verilerine göre minimum eğitim ve doğrulama kayıpları arasındaki fark 0.0107'dir. Eğitim ve doğrulama kaybı arasındaki fark 46 epochtan sonra ayrışma göstermiştir.




Şekil 17. İMF1, İMF2, İMF3, İMF4, İMF5, İMF6, İMF7 ve Kalan7 için eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses for IMF1, IMF2, IMF3, IMF4, IMF5, IMF6, IMF7 and Remainder7, test and validation data for true value and LSTM prediction values)

Meteorolojik verilere ait İMF1, İMF2, İMF3, İMF4, İMF5, İMF6, İMF7, İMF8 ve Kalan8 sinyalleri (48x8760 adet veri) giriş olarak kullanıldığında LSTM modeline ait eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 18’de gösterilmiştir. Bu giriş verilerine göre eğitimin ve doğrulama kayıplarının minimum değerleri sırasıyla 0.0035 ve 0.0133 olarak hesaplanmıştır. Bu giriş verilerine göre minimum eğitim ve doğrulama kayıpları arasındaki fark 0.098’dir. Fakat bu durum eğitim kaybının artısından kaynaklanmaktadır. Eğitim ve doğrulama kaybı arasındaki fark 67 epochtan sonra ayırışma göstermiştir.



Şekil 18. İMF1, İMF2, İMF3, İMF4, İMF5, İMF6, İMF7, İMF8 ve Kalan8 için eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses for IMF1, IMF2, IMF3, IMF4, IMF5, IMF6, IMF7, IMF8 and Remainder8, test and validation data for true value and LSTM prediction values)

Meteorolojik verileri herhangi bir ampirik mod sinyaline ayırılmadan doğrudan LSTM modelinin girişine uyguladığımızda LSTM modeline ait eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri Şekil 19’da gösterilmiştir.



Şekil 19. Meteorolojik verilerin doğrudan giriş olarak kullanılması sonucunda, eğitim ve doğrulama kayıpları, gerçek değer ve LSTM tahmin değerlerine ait test ve doğrulama verileri (Training and validation losses as a result of using meteorological data as direct input, test and validation data for actual and LSTM forecast values)

Bu giriş verilerine göre eğitim ve doğrulama kayıplarının minimum değerleri sırasıyla 0.005 ve 0.0528 olarak hesaplanmıştır. Meteorolojik veri setlerinin LSTM modelinde giriş olarak kullanılması sonucunda elde edilen tahmin sonuçlarına ait doğrulama ve test veri setlerine ait performans metrikleri Çizelge 3’te verilmiştir. Verilen bu çizelgenin sağ sütununun da herhangi bir AMA optimizasyonu uygulanmamış meteorolojik verilerin (Ham veri) giriş olarak kullanıldığı LSTM modeline ait doğrulama ve test performans metriklerini göstermektedir. Bu sonuçlara test ve doğrulamanın RES üretim tahminindeki MSE metrikleri sırasıyla 0.055 ve 0.052 olarak hesaplanmıştır. AMA optimizasyonu uygulanmış meteorolojik verilerin giriş olarak kullanıldığı LSTM modellerine ait RES üretim tahminlerinin performans kriterlerini incelediğimizde; test veri seti için en iyi MAE, MSE, RMSE ve R^2 metrikleri sırasıyla 0.079, 0.014, 0.119 ve 0.848 olarak İMF1-İMF5’de hesaplanmıştır. Doğrulama veri seti için en iyi MSE, RMSE ve R^2 metrikleri sırasıyla 0.079, 0.012, 0.111 ve 0.869 olarak İMF1-İMF5’de hesaplanmıştır. Doğrulama veri seti içerisinde en iyi MAE değeri 0.074 ile İMF1-İMF7’de hesaplanmıştır. Bu durum LSTM modelinde kayıp (lost) parametresi olarak MSE metriğinin belirlenmesinden kaynaklanmaktadır. Test veri seti için en kötü MAE, MSE, RMSE ve R^2 metrikleri sırasıyla 0.123, 0.032, 0.180 ve 0.651 olarak İMF1’de hesaplanmıştır. Doğrulama veri seti için en kötü MAE, MSE, RMSE ve R^2 metrikleri sırasıyla 0.127, 0.035, 0.189 ve 0.626 olarak İMF1’de hesaplanmıştır.

İMF sinyalleri LSTM tahmin sonuçları performans metriklerinin, ham veri seti LSTM tahmin sonuçları performans metriklerine göre yüzdesel değişimleri Çizelge 4’te verilmiştir. Verilen bu sonuçlara göre İMF sinyallerinin giriş olarak kullanıldığı LSTM modellerinin performans metrikleri ham veri setine kıyasla daha iyidir. Doğrulama veri seti üzerinden ham veri ile İMF sinyalleri arasındaki MAE, MSE, RMSE ve R^2 performans metriklerini karşılaştırdığımızda, en kötü performans İMF1 sinyalinde elde edilmiştir. Elde edilen bu sonuçlara göre ham veriye kıyasla MAE, MSE ve RMSE metrikleri sırasıyla %27,81, %32,29 ve %17,72 azalmıştır. R^2 ise %141,75 artmıştır. Test veri setinde de en kötü sonuçlar İMF1 sinyalinde elde edilmiştir. Test ve doğrulama veri setinde en iyi performans metrikleri İMF1-İMF5 veri setinde görülmüştür.

Çizelge 3. Test ve doğrulama verilerine ait RES üretim tahmini performans metrikleri (WPP generation forecast performance metrics for test and validation data)

		İMF1	İMF1, İMF2	İMF1-İMF3	İMF1-İMF4	İMF1-İMF5	İMF1-İMF6	İMF1-İMF7	İMF1-İMF8	Ham Veri
Doğrulama	MAE	0.12742	0.08596	0.07893	0.07581	0.07522	0.07567	0.07498	0.07771	0.17653
	MSE	0.03578	0.01792	0.01388	0.01333	0.01246	0.01278	0.01285	0.01332	0.05285
	RMSE	0.18916	0.13387	0.11783	0.11547	0.11163	0.11305	0.11338	0.11543	0.22989
	R ²	0.62605	0.81271	0.85489	0.86065	0.86977	0.86643	0.86565	0.86075	0.44167
Test	MAE	0.12302	0.09065	0.08211	0.08091	0.07931	0.08034	0.08062	0.08139	0.18178
	MSE	0.03272	0.01815	0.01455	0.01514	0.01429	0.01465	0.01438	0.01464	0.05501
	RMSE	0.18089	0.13475	0.12063	0.12305	0.11954	0.12105	0.11992	0.12100	0.23455
	R ²	0.65197	0.80687	0.84521	0.83896	0.84801	0.84414	0.84703	0.84427	0.41417

Çizelge 4. Ham veri setine göre, test ve doğrulama verilerine ait RES üretim tahmini performans metriklerinin yüzdesel değişimleri (Percentage changes of WPP generation forecast performance metrics for test and validation data relative to the raw data set)

		İMF1	İMF1, İMF2	İMF1-İMF3	İMF1-İMF4	İMF1-İMF5	İMF1-İMF6	İMF1-İMF7	İMF1-İMF8
Doğrulama	MAE	27.82	51.30	55.29	57.05	57.39	57.14	57.53	55.98
	MSE	32.29	66.09	73.73	74.77	76.42	75.82	75.68	74.79
	RMSE	17.72	41.77	48.74	49.77	51.44	50.82	50.68	49.79
	R ²	141.75	184.01	193.56	194.86	196.93	196.17	196.00	194.88
Test	MAE	32.33	50.13	54.83	55.49	56.37	55.80	55.65	55.22
	MSE	40.52	66.99	73.55	72.48	74.02	73.36	73.86	73.39
	RMSE	22.88	42.55	48.57	47.54	49.03	48.39	48.87	48.41
	R ²	157.42	194.81	204.07	202.56	204.75	203.81	204.51	203.84

4. SONUC (CONCLUSION)

Literatürde yer alan araştırmalarda LSTM modeli RES üretim tahmini gerçekleştirmek amacıyla ya ham meteorolojik veriler ya da içsel mod fonksiyonlarına ayrıştırılmış meteorolojik veriler kullanıldığı görülmüştür. Fakat LSTM modeli ile RES üretim tahmini için hangi içsel mod fonksiyonlarında daha iyi sonuçlar elde edilebileceği konusunda bir belirsizlik vardır. Yapılan bu çalışmada literatür de yer alan bu belirsizliği gidermek amacıyla en uygun İMF sayısının belirlenmesi amaçlanmıştır.

Bu amaçla, yapılan bu çalışmada rüzgâr enerjisi açısından yüksek bir potansiyele sahip İzmir ilinin 2022 yılı meteorolojik verileri ve RES üretim verileri kullanılarak en uygun İMF sinyal sayısının belirlenmesi amaçlanmıştır.

İzmir'e ait meteorolojik veriler farklı içsel mod fonksiyonlarına ayrıştırılmış ve LSTM modeli ile RES üretim tahmini için kullanılmıştır. Bu içsel mod fonksiyonlarına göre:

- Test veri seti ile LSTM modeli kullanılarak en iyi RES üretim tahmini İMF1-İMF5 içsel mod fonksiyonların da gerçekleştirilmiştir. İMF1-İMF5 giriş verilerine göre MAE, MSE, RMSE ve R²

performans metrikleri sırasıyla 0.079, 0.014, 0.119 ve 0.848 olarak hesaplanmıştır.

- Doğrulama veri seti ile LSTM modeli kullanılarak en iyi RES üretim tahmini İMF1-İMF5 içsel mod fonksiyonların da gerçekleştirilmiştir. İMF1-İMF5 giriş verilerine MSE, RMSE ve R² performans metrikleri sırasıyla 0.079, 0.012, 0.111 ve 0.869 olarak hesaplanmıştır.
- Test veri seti üzerinden ham veri ile İMF1-İMF5 arasındaki MAE, MSE, RMSE ve R² performans metriklerini karşılaştırdığımızda, ham veriye göre MAE, MSE ve RMSE metrikleri sırasıyla %56, %74 ve %49 azalmıştır. R² ise %204 artmıştır.
- Doğrulama veri seti üzerinden ham veri ile İMF1-İMF5 arasındaki MAE, MSE, RMSE ve R² performans metriklerini karşılaştırdığımızda, ham veriye göre MAE, MSE ve RMSE metrikleri sırasıyla %57, %76 ve %51 azalmıştır. R² ise %196 artmıştır.

Elde edilen tüm bu sonuçlar meteorolojik veriler ile LSTM ağ mimarisinde RES üretim tahmini için en uygun içsel mod fonksiyonunun İMF1-İMF5 olduğunu göstermektedir. İleride yapılacak çalışmalar da farklı yapay sinir ağları için en uygun içsel mod fonksiyonları belirlenebilir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasalölzel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

İsrafil KARADÖL: Makalenin yazım işleminin tüm süreçlerini gerçekleştirmiştir.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] Karadöl İ., Yıldız C., and Şekkel M., "Determining optimal spatial and temporal complementarity between wind and hydropower," *Energy*, vol. 230, (2021).
- [2] Cui Y., Chen Z., He Y., Xiong X., and Li F., "An algorithm for forecasting day-ahead wind power via novel long short-term memory and wind power ramp events," *Energy*, vol. 263, no. PC, p. 125888, (2023).
- [3] Saxena B. K., Mishra S., and Rao K. V. S., "Offshore wind speed forecasting at different heights by using ensemble empirical mode decomposition and deep learning models," *Appl. Ocean Res.*, vol. 117, no. May, p. 102937, (2021).
- [4] Kaysal K., Yurttakal A. H., and Hocaoglu F. O., "Hibrit derin öğrenme yöntemi kullanılarak hiperparametre optimizasyonu ile yenilenebilir elektrik enerjisi tahmini," *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilim. Derg.*, vol. 12, no. 3, pp. 770–777, (2023).
- [5] Shen Z., Fan X., Zhang L., and Yu H., "Wind speed prediction of unmanned sailboat based on CNN and LSTM hybrid neural network," *Ocean Eng.*, vol. 254, no. May, p. 111352, (2022).
- [6] Sun Y., Wang X., and Yang J., "Modified Particle Swarm Optimization with Attention-Based LSTM for Wind Power Prediction," *Energies*, vol. 15, no. 12, (2022).
- [7] Li J., Song Z., Wang X., Wang Y., and Jia Y., "A novel offshore wind farm typhoon wind speed prediction model based on PSO-Bi-LSTM improved by VMD," *Energy*, vol. 251, p. 123848, (2022).
- [8] Wang D., Cui X., and Niu D., "Wind Power Forecasting Based on LSTM Improved by EMD-PCA-RF," *Sustain.*, vol. 14, no. 12, (2022).
- [9] Zhang F., Guo Z., Sun X., and Xi J., "Short-term wind power prediction based on EMD-LSTM combined model," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 514, no. 4, (2020).
- [10] Ding Y., Ye X. W., and Guo Y., "A Multistep Direct and Indirect Strategy for Predicting Wind Direction Based on the EMD-LSTM Model," *Struct. Control Heal. Monit.*, vol. 2023, (2023).
- [11] Chen Y. et al., "Short-term wind speed predicting framework based on EEMD-GA-LSTM method under large scaled wind history," *Energy Convers. Manag.*, vol. 227, no. October 2020, p. 113559, (2021).
- [12] Ai X., Li S., and Xu H., "Wind speed prediction model using ensemble empirical mode decomposition, least squares support vector machine and long short-term memory," *Front. Energy Res.*, vol. 10, no. January, pp. 1–12, (2023).
- [13] Yang Y. and Yang Y., "Hybrid prediction method for wind speed combining ensemble empirical mode decomposition and bayesian ridge regression," *IEEE Access*, vol. 8, pp. 71206–71218, (2020).
- [14] Lotfipoor A., Patidar S., and Jenkins D. P., "Deep neural network with empirical mode decomposition and Bayesian optimisation for residential load forecasting," *Expert Syst. Appl.*, vol. 237, no. PA, p. 121355, (2024).
- [15] Yıldız C., Acikgoz H., Korkmaz D., and Budak U., "An improved residual-based convolutional neural network for very short-term wind power forecasting," *Energy Convers. Manag.*, vol. 228, Jan. (2021).
- [16] Jaseena K. U. and Kovoov B. C., "Decomposition-based hybrid wind speed forecasting model using deep bidirectional LSTM networks," *Energy Convers. Manag.*, vol. 234, no. November (2020), p. 113944, (2021).
- [17] Aladağ E., "Ampirik Mod Ayrıştırmasına Dayalı ARIMA Modeli Kullanılarak Van İli Hava Kirliliğinin Tahmini," *Yüzüncü Yıl Üniversitesi Fen Bilim. Enstitüsü Derg.*, vol. 28, no. 2, pp. 495–509, (2023).
- [18] Dişili F., Gedikpinar M., and Şengür A., "Kırık Rotor Çubuğu Sayısının Ampirik Mod Ayrışımı v e Makine Öğrenmesi Yaklaşımları İle Belirlenmesi," *Fırat Üniversitesi Müh. Bil. Derg.*, vol. 35, no. 2, pp. 783–795, (2023).
- [19] Bekçioğulları M. F., Dikici B., Açıkgoz H., and Keçecioglu Ö. F., "Güneş Enerjisinin Kısa-Dönem Tahmininde Farklı Makine Öğrenme Yöntemlerinin Karşılaştırılması," *EMO Bilim. Dergi*, vol. 11, no. 22, pp. 37–45, (2021).
- [20] Bokde N., Feijóo A., Al-Ansari N., Tao S., and Yaseen Z. M., "The hybridization of ensemble empirical mode decomposition with forecasting models: Application of short-term wind speed and power modeling," *Energies*, vol. 13, no. 7, pp. 1–23, (2020).
- [21] Yu M., "Short-term wind speed forecasting based on random forest model combining ensemble empirical mode decomposition and improved harmony search algorithm," *Int. J. Green Energy*, vol. 17, no. 5, pp. 332–348, (2020).
- [22] Jiang T. and Liu Y., "A short-term wind power prediction approach based on ensemble empirical mode decomposition and improved long short-term memory," *Comput. Electr. Eng.*, vol. 110, no. March, p. 108830, (2023).
- [23] Xu Y. et al., "Research on particle swarm optimization in LSTM neural networks for rainfall-runoff simulation," *J. Hydrol.*, vol. 608, no. August 2020, p. 127553, (2022).
- [24] Ewees A. A., Al-qaness M. A. A., Abualigah L., and Elaziz M. A., "HBO-LSTM: Optimized long short term memory with heap-based optimizer for wind power forecasting," *Energy Convers. Manag.*, vol. 268, no. May, p. 116022, (2022).