

LED Aydınlatma Sistemlerinde Derin Öğrenme Tabanlı Harmonik Tahminleme Deep Learning Based Harmonic Estimation in LED Illumination Systems

¹İlyas ÖZER , ²Harun ÖZBAY , ³Serhat Berat EFE 

^{1,2,3}Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bandırma/Balıkesir, Türkiye

¹iozer@bandirma.edu.tr, ²hozbay@bandirma.edu.tr,

³sefe@bandirma.edu.tr,

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 13 September 2022

Accepted : 2 October 2022

Keywords:

LED Illumination, Energy Quality, Deep Learning, Machine Learning

ABSTRACT

LED illumination systems are frequently used in both indoor and outdoor lighting, and these elements offer great advantages especially in terms of energy efficiency. However, these systems cause energy quality problems due to the switching elements included in the driver circuits necessary for their operation. The main motivation of this study is the estimation of the power quality distortions, which are called harmonics, produced by the related systems. In this context, electrical data were measured from an experimentally designed LED lighting system and power quality problems caused by the relevant system were revealed as a result of the necessary calculations. However, based on the fact that the enlargement of the system size will increase the computational complexity, a deep learning-based algorithm has been developed to detect the aforementioned problems. Quality distortions were estimated by using basic electrical parameters free from computational complexity, in the GRU and BiGRU models, the lowest MAE value was 0,031 and the lowest RMSE value was 0,099 compared to actual data. The same values were realized as 0,028 and 0,097 in LSTM and BiLSTM models, respectively.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 13 Eylül 2022

Kabul : 2 Ekim 2022

Anahtar Kelimeler:

LED Aydınlatma, Enerji Kalitesi, Derin Öğrenme, Makine Öğrenmesi

ÖZET

LED aydınlatma sistemleri, hem iç hem de dış aydınlatmada sıklıkla kullanılmakta olup, bu elemanlar özellikle enerji verimliliği bakımından büyük avantajlar sunmaktadır. Ancak söz konusu sistemler, çalışmalarını için gerekli olan sürücü devrelerinin içerdiği anahtarlama elemanları nedeniyle, enerji kalitesi açısından sorunlara neden olmaktadır. Bu çalışmanın temel motivasyonunu, ilgili sistemler tarafından üretilen ve harmonik adı verilen güç kalitesi bozulmalarının tahminlenmesi oluşturmaktadır. Bu kapsamda, deneysel olarak tasarlanan bir LED aydınlatma sisteminden elektriksel veriler ölçülerek gerekli hesaplamalar sonucunda ilgili sistemin neden olduğu güç kalitesi problemleri ortaya çıkarılmıştır. Ancak sistem boyutunun büyümesinin hesaplama karmaşasını artıracığından yola çıkılarak, bahse konu problemlerin tespiti için derin öğrenme tabanlı bir algoritma geliştirilmiştir. Kalite bozulmaları, temel elektriksel parametreler kullanılmış ve hesaplama karmaşasından arındırılarak tahminlenmiş, gerçek veriler ile karşılaştırıldığında, GRU ve BiGRU modellerinde en düşük MAE değeri 0,031 ve en düşük RMSE değeri ise 0,099 olarak elde edilmiştir. Aynı değerler LSTM ve BiLSTM modellerinde sırasıyla 0,028 ve 0,097 olarak gerçekleşmiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Dünya genelinde elektrik enerjisinin yaklaşık %20'lik kısmı aydınlatma amacıyla kullanılmaktadır. Bu durum araştırmacıları daha verimli aydınlatma elemanları geliştirmeye yönlendirmiş ve bu kapsamda hem iç hem de dış aydınlatmada kullanılan, ışık yayan diyot (Light Emitting Diode – LED) tabanlı aydınlatma sistemleri geliştirilmiştir [1], [2]. Bu sistemler enerji verimliliği bakımından %90'lara varan iyileştirme sağlayabilmektedir. Ancak enerji verimliliği yönüyle büyük avantaja sahip olan bu sistemler, mimarilerinde bulunan yarıiletken elemanlardan oluşan güç elektroniği temelli sürücü devreleri nedeniyle enerji kalitesinde bozulmalara yol açmaktadır [3]–[5]. Harmonik adı verilen bu bozulmalar, gerilim dalgalarında da ortaya çıkmakla birlikte en büyük etkiyi akım dalga şeklinde göstermektedir.

Harmonikler, en genel tanımıyla akım ve gerilim dalga şekillerindeki bozulmalardır. Toplam harmonik distorsiyon (THD) belirli limitlerin üzerine çıktığında birçok elektriksel probleme neden olur. Bu nedenle literatürde harmonik analizi ve harmonik filtreleme çalışmaları oldukça geniş bir yer bulmaktadır [6]. THD, harmonik bileşenlerinin etkin RMS değerlerinin ana bileşenin etkin değerine oranıdır ve dalga şeklindeki bozulmayı yüzde olarak ifade eder. THD, akım ve gerilim için sırasıyla Denklem 1 ve Denklem 2'de verildiği şekilde tanımlanır.

$$THD_I = \frac{1}{I_1} \sqrt{\sum_{n=2}^{\infty} I_n^2} \quad (1)$$

$$THD_V = \frac{1}{U_1} \sqrt{\sum_{n=2}^{\infty} U_n^2} \quad (2)$$

Harmoniklerin belirlenmesi için matematiksel tanımlara ihtiyaç duyulmaktadır. Harmonikler matematiksel olarak Denklem 3-6 arasında verilen eşitlikler ile tanımlanabilir.

$$\text{Harmonik: } f = kf_0 \quad (3)$$

$$\text{Ara-harmonik: } f \neq kf_0 \quad (4)$$

$$\text{Alt-harmonik: } f > 0 \text{ ve } f < f_0 \quad (5)$$

$$\text{Doğru Akım Bileşeni: } n = 0 \text{ için } f = nf_0 \quad (6)$$


Burada k sıfırdan büyük bir tamsayıyı, f : sinyalin spektral bileşen frekansını ve f_0 temel frekansını ifade etmektedir [7]. Aydınlatma ekipmanlarında harmonik akım emisyon limitleri için Uluslararası Elektroteknik Komisyonunun (IEC) 61000-3-2:2018 standardı dikkate alınmaktadır [8].

Harmonik analizi için geçmişten bugüne Hızlı Fourier dönüşümü [9] gibi geleneksel teknikler kullanılmakla birlikte, son yıllarda, bilgisayar teknolojilerinin hızlı gelişimi sayesinde fazla veri işlemesine ve daha kesin sonuçlar elde edilebilmesine olanak tanıyan yapay zekâ yaklaşımları popüler hale gelmiştir [10], [11].

Harmoniklerin oluştuğu anda tespit edilmesinin yanı sıra, bu çalışmada harmoniklerin oluşmadan önce hızlı ve doğru bir şekilde tahmin edilmesi amaçlanmıştır. Gerçek bir deneysel sistemden elde edilen veriler kullanılmıştır. Bu durum, elemanların bağlantı noktalarında oluşan kayıplar ve meteorolojik etkiler gibi benzetim çalışmalarında göz ardı edilmesi olası tüm parametrelerin hesaplamaya katılmasını sağlamıştır.

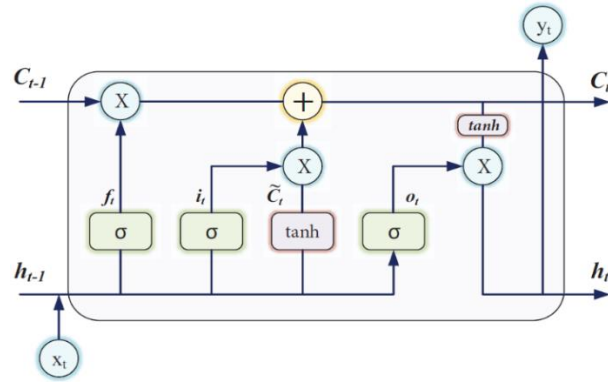
2. TAHMİNLEME MODELLERİ

Makine öğrenmesi uygulamalarında yapay sinir ağları (YSA) yaygın olarak kullanılmaktadır. Farklı veri türlerini işlemek için zaman içerisinde farklı YSA modelleri tasarlanmıştır. Bu kapsamda dizi verilerini işlemek için tekrarlayan sinir ağları (RNN'ler) geliştirilmiştir. Klasik ileri beslemeli YSA'lar, yalnızca girdi olarak mevcut örnekleri dikkate alsa da, RNN'ler, mevcut örneklerin yanı sıra zaman içinde algıladıklarını da girdi olarak uygular [12]. Bu özellikleri sayesinde RNN'ler tahminleme çalışmalarında sıklıkla kullanılmaya başlanmıştır [13]. RNN blok şeması Şekil 1'de gösterilmiştir.



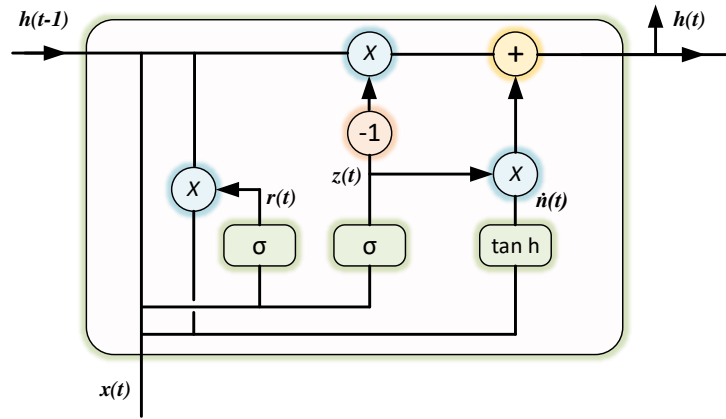
Şekil 1. RNN Mimarisi.

Uzun-Kısa Dönemli Hafıza (LSTM) ise özelleştirilmiş bir RNN yapısı olarak tanımlanabilir. LSTM modelleri konuşma tanıma, dil modelleme, talep gücü ve enerji kalitesi tahminlemeye kadar birçok alanda kullanılmaktadır [14]–[18]. LSTM blok şeması Şekil 2’de verilmiştir.



Şekil 2. LSTM Blok şeması.


Öte yandan, Cho vd. tarafından, güç sistemi tahmin çalışmaları için en çok kullanılan alternatif tekniklerden biri olan ve kapılı tekrarlayan birim (GRU) olarak adlandırılan bir başka model geliştirilmiştir [19]. GRU, unutmaya kapısı olan bir LSTM'ye benzer, ancak bir çıkış kapısı olmadığı için bir LSTM'den daha az parametreye sahiptir. Literatürdeki bazı çalışmalar, GRU'ların LSTM'lerden daha iyi performans gösterebileceğini [20] bazıları ise buna tam zıt sonuçlar ortaya çıkabileceğini [21] göstermektedir. GRU blok yapısı Şekil 3'te gösterilmiştir.



Şekil 3. GRU Blok yapısı.


3. UYGULAMA SİSTEMİ

Bu çalışmada, LED aydınlatma elemanları kaynaklı ortaya çıkan harmoniklerin makine öğrenmesi modelleri ile tahminlenmesi yapılmıştır. Bu yaklaşım, hesaplama adımlarının atlanarak sonuca doğrudan ulaşılabilmesi açısından büyük avantaj sağlamaktadır. Bu kapsamda Şekil 4'te gösterilen uygulama sistemi tasarlanmıştır ve bu sistem kullanılarak deneysel veriler kaydedilmiştir.



Şekil 4. Uygulama sistemi.

Deneyisel veriler kaydedilirken bu işlem için tasarlanan ve yüksek örnekleme frekansına sahip bir ölçüm devresi kullanılmıştır [22]. Bu devre Şekil 5'te gösterilmiştir.



Şekil 5. Ölçüm kartı.

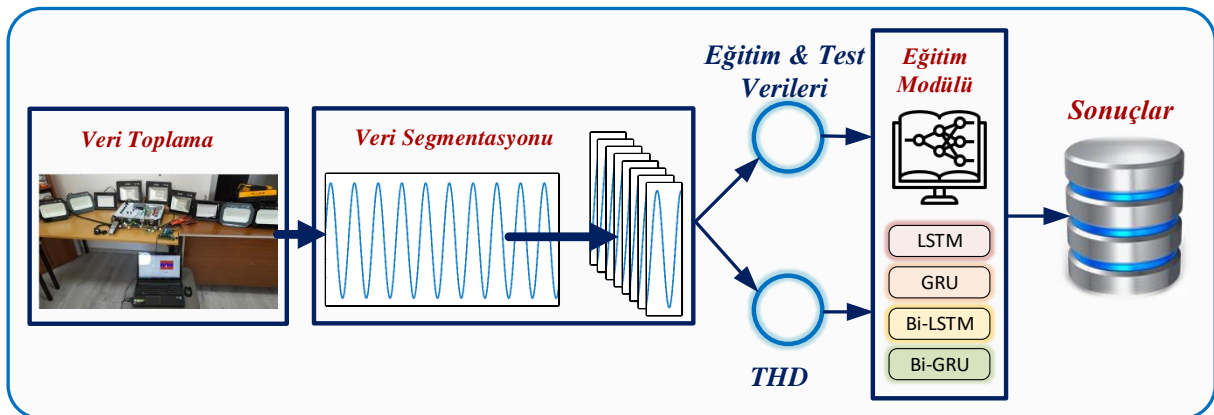
Uygulama sistemi, 3 adet 50 W, 2 adet 100 W, 2 adet 150 W ve 2 adet 200 W gücünde LED projektör kullanılarak tasarlanmıştır. Tüm projektörler devredeyken 4 m uzaklıkta toplam 3939 lüks değerinde aydınlık düzeyi değeri ölçülmüştür. Elektriksel parametreler Şekil 5'te gösterilen ölçüm kartı ile kaydedilerek işlenmesi amacıyla taşınabilir bilgisayara aktarılmıştır.

4. DENEYSEL SONUÇLAR VE TARTIŞMA

Harmoniklerin tespit edilmesi, güç kalitesi problemleri ile etkin bir mücadele gerçekleştirebilmek için oldukça kritik bir unsurdur. Ayrıca güç sistemlerinin dinamik yapısı gereği harmonikler zaman içerisinde sürekli olarak değişmektedir. Bu nedenle şebekede harmoniklerin sürekli olarak izlenmesi gerekir. Öte yandan iletim sistemindeki her bir veri yolunun analizörler, harmonik ölçerler veya güç analizörü gibi cihazlar vasıtasıyla izlenmesi yüksek maliyetler nedeniyle her zaman mümkün olmamaktadır [23]. Bu tarz cihazlarda yaygın olarak hızlı Fourier dönüşümü (HFD) ile harmonik hesabı gerçekleştirilmektedir.

Bu çalışma kapsamında harmoniklerin HFD kullanılarak hesaplanması yerine doğrudan akım verisi üzerinden yapay sinir ağları (YSA) tabanlı bir model ile tahmin edilmesi hedeflenmektedir. Bu doğrultuda RNN tabanlı LSTM ve GRU ağlarının kullanılması önerilmiştir. Bu ağlar aralarında zamansal bağımlılık olan veriler üzerinde diğer birçok YSA modeline kıyasla oldukça yüksek performans sergilemektedir.

Uygulama sisteminden ölçülen ve kaydedilen veriler, çalışmanın amacı kapsamında çeşitli basamaklar halinde işlenmiştir. İşlem basamakları Şekil 6' da verilen blok şemada özetlenmiştir.



Şekil 6. Veri işleme ve tahminleme işlem basamakları.

Veri toplama kartından alınan akım verileri her biri 300 noktadan oluşan veri segmentlerine ayrılmaktadır. Her bir segmentin THD değeri HFD ile hesaplanmaktadır. Bu değerler modelin eğitimi ve test işlemi aşamasında model

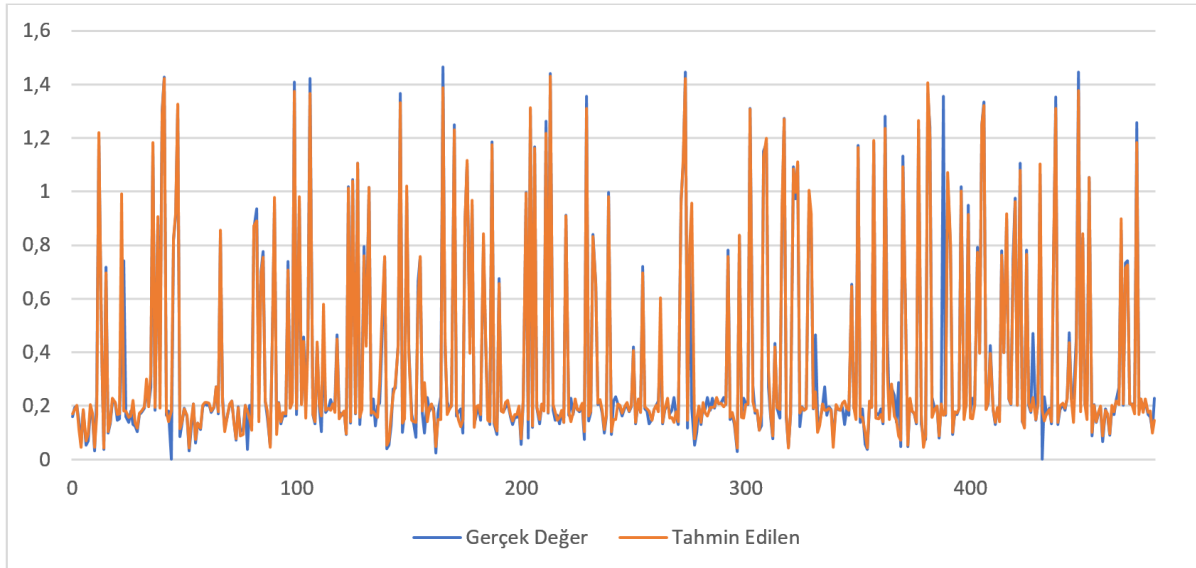
performansının kıyaslanması amacıyla kullanılmaktadır. Tüm ölçüm verilerinin %80'i modellerin eğitimi kalan %20'lik bölümü de test işlemi için ayrılmıştır. 300 noktadan oluşan her bir veri segmenti modellere girdi olarak uygulanırken THD verileri de çıktı bilgisi olarak ele alınmaktadır. . Bu doğrultuda toplam 724.500 adet akım verisinden 2415 adet segment elde edilmiş ve bunların 1932 adeti eğitim için geriye kalan 483 adeti ise test işlemi için ayrılmıştır.

Bu çalışma kapsamında THD değerinin tahmin edilmesi için 8 farklı model kullanılmıştır. Bu modeller LSTM, BiLSTM, GRU ve BiGRU ağlarından oluşmaktadır. Tahmin için kullanılan modeller girdi, LSTM/GRU ve çıktı katmanlarından oluşmaktadır. LSTM/GRU katmanlarının yerine çift yönlü versiyonları (BiLSTM/BiGRU) da kullanılmıştır. Ayrıca bunların tek katman ve iki katmandan oluşan mimarileri de test edilmiştir. Gizli katmanlardaki nöron sayısı 100 olarak belirlenmiştir. Optimizasyon metodu olarak Adam algoritması tercih edilmiştir. Tüm modeller 500 tekrar boyunca eğitilmiş ve test işlemi için en küçük kayıp değerine sahip olan ağırlıklar kullanılmıştır. Tahmin edilen THD değerlerini gerçek THD değeri ile kıyaslamak için RMSE ve MAE hata değerleri hesaplanmıştır. Tablo 1'de, 8 ayrı testin sonucuna ilişkin skorlar verilmiştir.

Tablo 1. Modellerin hata değerlerinin karşılaştırılması.


		LSTM	BiLSTM	GRU	BiGRU
1 Katman	RMSE	0,100	0,106	0,109	0,104
	MAE	0,033	0,031	0,039	0,034
2 Katman	RMSE	0,097	0,101	0,099	0,106
	MAE	0,031	0,028	0,031	0,032

GRU ve BiGRU modellerinde en düşük MAE değeri 0,031 ve en düşük RMSE değeri ise 0,099 olarak elde edilmiştir. Aynı değerler LSTM ve BiLSTM modellerinde sırasıyla 0,028 ve 0,097 olarak gerçekleşmiştir. Genel olarak LSTM ve BiLSTM modellerine ilişkin hata değerlerinin GRU tabanlı modellere kıyasla daha iyi olduğu görülmektedir. Bunun sonucunun LSTM tabanlı ağların uzun süreli bağımlılıkları yakalama noktasındaki başarısından kaynaklandığı değerlendirilmektedir. LSTM ve BiLSTM modellerinde iki katman kullanmanın sonuca olumlu katkı sağladığı görülmektedir. LSTM modellerinde bir ve iki katman için RMSE değerleri sırasıyla 0,1 ve 0,097 olarak gerçekleşmiştir. MAE değerleri ise sırasıyla 0,33 ve 0,31'dir. BiLSTM modellerinde tek katman için RMSE ve MAE değerleri 0,106 ve 0,031'dir. İki katmanlı BiLSTM modelinde bu değerler sırasıyla 0,101 ve 0,028 olarak gerçekleşmiştir.



Şekil 7. İki katmanlı LSTM modeline ait gerçek ve tahmin edilen THD değerleri.

Şekil 7'de iki katmanlı LSTM modelinin gerçek ve tahmin edilen değerleri görülmektedir. İki katmanlı BiLSTM modeline ait değerler ise Şekil 8'de verilmiştir. Sonuç olarak tahmin edilen değerlerin büyük ölçüde gerçek değerler ile örtüştüğü görülmektedir.



Şekil 8. İki katmanlı BiLSTM modeline ait gerçek ve tahmin edilen THD değerleri.

5. SONUÇ

LED aydınlatma elemanları, yapılarında barındırdıkları ve çalışmaları için gerekli olan sürücü devreleri nedeniyle birer harmonik kaynağıdır. Bu yapıların fazla sayıda bir arada kullanılması ile elde edilen aydınlatma sistemleri ise elektrik enerji şebekesi üzerinde büyük bozucu etkilere neden olmaktadır. Enerji sisteminin düzgün çalışması ve şebekeye bağlı kullanıcılara kaliteli enerji arzı için söz konusu harmoniklerin detaylı biçimde tespit edilmesine ve analizine ihtiyaç vardır. Bu çalışmada, LED aydınlatma sistemlerinden kaynaklanan harmoniklerin, hesaplama adımlarına ihtiyaç olmadan tahminlenmesi amacıyla derin öğrenme temelli bir algoritma geliştirilmiştir.

Güç sistemlerinin analizinde ve özellikle enerji kalitesi çalışmalarında, sistemdeki tüm parametrelerin hesaba katılması ve gerçeğe en uygun sonuçların elde edilmesi açısından deneysel verilerin kullanılması önem arz etmektedir. Bu nedenle, çalışma kapsamında deneysel bir sistem oluşturularak veriler elde edilmiş, önerilen tahminleme modelinin eğitimi ve testleri bu veriler kullanılarak yapılmıştır.

Bu çalışmada enerji kalitesindeki bozulmalar, 8 farklı modelle tahminlenmiştir. Bu modeller LSTM, BiLSTM, GRU ve BiGRU ağlarından oluşmaktadır. Ayrıca bunların tek katman ve iki katmandan oluşan mimarileri de test edilmiştir. Tahmin edilen THD değerlerini gerçek THD değeri ile kıyaslamak için RMSE ve MAE hata değerleri hesaplanmış, grafikler ve tablolar üzerinden değerlendirilerek tartışılmıştır. Buna göre, GRU ve BiGRU modellerinde en düşük MAE değeri 0,031 ve en düşük RMSE değeri ise 0,099 olarak elde edilmiştir. Aynı değerler LSTM ve BiLSTM modellerinde sırasıyla 0,028 ve 0,097 olarak gerçekleşmiştir. Ortaya çıkan sonuçlar üzerinden genel değerlendirme yapıldığında, hata değerleri bakımından LSTM ve BiLSTM modellerinin GRU tabanlı modellere kıyasla daha iyi performans gösterdiği tespit edilmiştir. Bunun durumun, LSTM tabanlı ağların uzun süreli bağımlılıkları yakalama noktasındaki başarısından kaynaklandığı değerlendirilmektedir.

Yazar Katkıları

Tüm yazarların çalışmadaki katkı oranları eşittir.

Çıkar Çatışması

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

Destek ve Teşekkür Beyanı

Bu çalışma Bandırma Onyedü Eylül Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje Numarası: BAP-20-1004-004.

KAYNAKÇA

- [1] O. Akalp, H. Ozbay, and S. B. Efe, "Design and Analysis of High-Efficient Driver Model for LED Luminaires," *Light Eng.*, vol. 29, no. 2, pp. 96–106, 2021.
- [2] S. B. Efe and D. Varhan, "Interior Lighting of a Historical Building by using LED Luminaires: A Case Study of Fatih Paşa Mosque," *Light Eng.*, vol. 28, no. 4, pp. 77–83, 2020.

- [3] M. S. Cengiz, "The relationship between maintenance factor and lighting level in Tunnel lighting," *Light Eng.*, vol. 27, no. 3, pp. 75–84, 2019.
- [4] M. S. Cengiz and Ç. Cengiz, "Numerical analysis of tunnel LED Lighting maintenance factor," *IIUM Eng. J.*, vol. 19, no. 2, pp. 154–163, 2018.
- [5] M. S. Cengiz and S. Yetkin, "Thermal Analysis in Fixed, Flowed and Airless Environment for Cooling in LED Luminaires," *Light Eng.*, vol. 28, no. 6, pp. 28–35, 2020.
- [6] S. Rüstemli and M. S. Cengiz, "Active filter solutions in energy systems," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 23, pp. 1587–1607, 2015.
- [7] S. B. Efe, H. Özbay, and İ. Özer, "Dynamic Voltage Restorer Application to Eliminate Power System Harmonics," in *International Engineering and Natural Sciences Conference (IENSC 2019)*, pp. 705–709, 2019.
- [8] International Electrotechnical Commission (IEC). IEC 61000-3-2:2018., "Electromagnetic Compatibility (EMC)—Part 3-2: Limits—Limits for Harmonic Current Emissions (Equipment Input Current ≤ 16 A per Phase)." <https://webstore.iec.ch/publication/62553>
- [9] J. Valenzuela and J. Pontt, "Real-time interharmonics detection and measurement based on FFT algorithm," *2009 Appl. Electron. Int. Conf. AE 2009*, no. 1, pp. 259–264, 2009.
- [10] N. Severoglu and O. Salor, "Statistical Models of EAF Harmonics Developed for Harmonic Estimation Directly from Waveform Samples Using Deep Learning Framework," *IEEE Trans. Ind. Appl.*, vol. 57, no. 6, pp. 6730–6740, 2021.
- [11] N. Severoglu and O. Salor, "Amplitude and phase estimations of power system harmonics using deep learning framework," *IET Gener. Transm. Distrib.*, vol. 14, no. 19, pp. 4089–4096, 2020.
- [12] İ. Özer, S. B. Efe, and H. Özbay, "CNN / Bi-LSTM-based deep learning algorithm for classification of power quality disturbances by using spectrogram images," *Int. Trans. Electr. Energy Syst.*, vol. 31, no. 12, pp. 1–16, 2021.
- [13] H. Özbay and A. Dalcali, "Effects of COVID-19 on electric energy consumption in Turkey and ANN-based short-term forecasting," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 29, no. 1, pp. 78–97, 2021.
- [14] I. Ozer, S. B. Efe, and H. Ozbay, "A combined deep learning application for short term load forecasting," *Alexandria Eng. J.*, vol. 60, no. 4, pp. 3807–3818, 2021.
- [15] I. Ozer, Z. Ozer, and O. Findik, "Noise robust sound event classification with convolutional neural network," *Neurocomputing*, vol. 272, pp. 505–512, 2018.
- [16] Z. Ozer, I. Ozer, and O. Findik, "Diacritic restoration of Turkish tweets with word2vec," *Eng. Sci. Technol. an Int. J.*, vol. 21, no. 6, pp. 1120–1127, 2018.
- [17] I. Ozer, Z. Ozer, and O. Findik, "Lanczos kernel based spectrogram image features for sound classification," *Procedia Comput. Sci.*, vol. 111, no. 2015, pp. 137–144, 2017.
- [18] J. Bedi and D. Toshniwal, "Deep learning framework to forecast electricity demand," *Appl. Energy*, vol. 238, no. July 2018, pp. 1312–1326, 2019.
- [19] K. Cho et al., "Learning phrase representations using RNN encoder-decoder for statistical machine translation," *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.*, pp. 1724–1734, 2014.
- [20] R. Jozefowicz, W. Zaremba, and I. Sutskever, "An empirical exploration of Recurrent Network architectures," in *32nd International Conference on Machine Learning, ICML 2015*, vol. 3, pp. 2332–2340, 2015.
- [21] D. Amodei and Et.al, "Deep Speech 2 : End-to-End Speech Recognition in English and Mandarin," in *International Conference on Machine Learning, 2016*, vol. 48, pp. 1–10.
- [22] S. B. Efe, H. Ozbay, and I. Ozer, "Experimental Design and Analysis of Adaptive LED Illumination System," *Light Eng.*, vol. 30, no. 4, pp. 63–70, 2022.
- [23] S. K. Jain and S. N. Singh, "Harmonics estimation in emerging power system: Key issues and challenges," *Electr. Power Syst. Res.*, vol. 81, no. 9, pp. 1754–1766, 2011.