

Elektrik Güç Kalitesi Bozulmalarının Uzun Kısa-Süreli Bellek Tabanlı Sinir Ağları ile Sınıflandırılması

Classification of Electrical Power Quality Disturbances using Long Short-Term Memory Based Neural Networks

Volkan Yamaçlı

Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi
Mersin Üniversitesi, Mersin, Türkiye
vyamacli@mersin.edu.tr

 0000-0003-0331-8818

Özet

Güç kalitesi bozulma tespiti ve sınıflandırması, güç elektroniği ekipmanlarının, yeşil enerjinin ve akıllı şebekelerin oluşturulmasının artan ihtiyacı ve kullanımı göz önüne alındığında hayati öneme sahiptir. Sadece teknolojik açıdan değil, aynı zamanda ekonomik açıdan da ekipman arızalarının oluşmaması ve erken müdahalenin sağlanabilmesi için önem arz etmektedir. Güç kalitesi bozulmasına örnek olarak harmonikler, gerilim artışı ve düşüşleri, geçiş karakteristikleri, gerilim işaret frekansının artışı ve azalışı ile gerilim çentigi gibi olaylar örnek verilebilir. Bu ve benzer bozulmaların hassas yükleri ve bağlı sistemleri etkilemeden önce mümkün olan en kısa sürede belirlenmesini ve önleyici eylemlerin uygulanmasını gerektirmektedir. Bu çalışmada, çeşitli güç kalitesi bozulmalarını temsil eden işaret karakteristikleri tekrarlayan sinir ağı metodlarından olan uzun kısa-süreli bellek ile en kısa sürede tespit ve sınıflandırılması sağlanmasına yönelik çalışmalar gerçekleştirilmiştir. Yapılan farklı durum ve sınıflama çalışmalarında %80 ile %97 arasında test başarıları elde edilmesi yaklaşımın verimliliği ve doğruluğunu ifade etmektedir.

Anahtar Kelimeler — güç kalitesi bozulmaları; güç kalitesi ve kontrolü; elektriksel bozulmalar; uzun kısa-süreli bellek.

Abstract

Power quality disturbance detection and classification are of vital importance considering the increasing need and use of power electronic equipment, green energy and smart grids. It is important not only from a technological perspective but also from an economic perspective to prevent equipment failures and to provide early intervention. Examples of power quality disturbances include harmonics, voltage increases and decreases, transition characteristics, voltage signal frequency disturbances, and voltage notches. These disturbances should be determined as soon as possible before they affect sensitive loads and connected systems. In this study, they were carried out to detect and classify signal characteristics representing various power quality disturbances with long short-term memory. The fact that test success rates between 80% and 97% were achieved in different situations and classification studies indicates the efficiency and accuracy of the approach.

Keywords — power quality disturbances; power quality and control; electrical disturbances; long short-term memory.

1. Giriş

Son yıllarda gerilim ve akım bozulmalarından arınmış temiz güç sağlama konusundaki artan talep, elektrik gücü kalitesinde sürekli ve anlık olarak meydana gelebilen bozulma tespiti ve sınıflandırması alanına olan ilgi ve çalışmaların artmasını sağlamıştır. Güç kalitesi terimi, güç sisteminde belirli bir zaman ve konumdaki voltajı ve akımı karakterize eden çok çeşitli elektromanyetik fenomenler olarak tanımlanabilir. Gerilimin yükselmesi, düşüşü, gerilim titremesi, gerilim çentigi, harmonikler, anlık kesintileri, salınımlı geçişi ve bunların kombinasyonları yaygın güç kalitesi (PQ) olaylarından bazılarıdır [1]. Elektrik güç sistemlerindeki güç kalitesi bozulmalarında (PQD) senkron olmayan frekanslı sürücüler, AC iletim cihazları, güç elektroniği dönüştürücüler, ark üretim cihazları ve doğrusal olmayan yükler gibi birçok etken vardır. Sıklıkla karşılaşılan PQD nedenleri arasında uzak ve yerel arızalar, yük anahtarlama, kapasitör anahtarlama, doğrusal olmayan yüklerin varlığı, aşırı yükleme gibi etmenler de yer alabilmektedir [2, 3]. Dalga formu-zaman istatistiksel özelliklerine dayanarak, mevcut PQD'ler anlık ve sürekli bozulmalar olarak iki ana gruba ayrılabilir [4]. Anlık bozulmalar arklar ve çentiklere benzer anlık bozulmalar olmakla birlikte sürekli bozulmalar ise harmonikler gibi dalga formunu sürekli bir biçimde periyodik olarak etkileyen bozulmalardır [1]. Genel olarak, bu elektriksel bozulmalar, bir zaman aralığındaki gerilim veya akım dalga formunun normal değerlerine göre genlik veya frekanstaki anormalliklerdir. Güç kalitesi olayları zamana bağlı istatistiksel özelliklere göre sınıflandırılır [5, 6]. PQ bozulmaları IEEE (Institute of Electrical and Electronics Engineers) standardı 1159 [7] ve Avrupa standardı EN (European Norm) 50160 [8] tarafından kategorize edilir. Bununla birlikte IEEE 1547 standardı da elektrik enerji kalitesi ile ilgili durumları belirlemektedir [9]. Bu standartlarda genellikle meydana gelebilecek bir bozulmanın büyüklüğü, tespit süresi ve düzeltilme süresi ile ilgili değerlere yer verilmektedir.

Günümüzde elektrik enerji kalitesi hem evsel kullanıcılar hem de endüstriyel kullanıcılar için büyük önem teşkil etmektedir. Özellikle endüstriyel üretim tesislerinde birçok cihaz ve ekipman elektrik enerjisi ile çalışmakta, meydana gelebilecek bir PQD hem çalışan cihazı hem de buna bağlı olarak tüm seri üretimi sektöre uğratabilecek boyutlara gelebilmektedir. Bu tür hassas endüstriyel ekipmanlar, mümkün olan en kısa sürede doğru bir şekilde tanımlarsa bu tehlikeli değişikliklerden korunabilir. Hızlı işlemeye doğru tespit ve tanıma, PQD'lerin etkisinin azaltılması için kullanılan bir kontrol ve izleme sisteminin verimliliğini önemli ölçüde

artırabilir. Farklı araştırmacılar tarafından çeşitli PQD tespit ve sınıflandırma teknikleri sunulmuştur. Öncelikle bazı işaret ön işleme teknikleri kullanılmıştır. Bu teknikler arasında, dalgacık paket dönüşümü (WPT) ve destek vektör makineleri (SVM) kullanan bir güç bozulması olayı tanıma tekniği kullanılarak iyi bir başarı elde edilmiştir [10]. Yapay sinir ağı (ANN) ile ampirik mod ayrıştırma (EMD) metodları ile başka bir çalışmada yüksek doğruluklu bir netice alınabilmiştir. [11]. Sıkıştırılmış algılama (CS) ve derin evrişimli sinir ağları (DCNN) ile birçok sınıfta sunulan PQD'ler başarılı biçimde tanımlanabilmiştir [12]. Bununla birlikte sinir ağı (NN) ile birleştirilen Stockwell dönüşümü (SWT) tekniği de %94 üzerinde bir başarı ile sunulabilmiştir [13]. Özellikle derin öğrenmenin yükselişe geçmesi ile, elektrik enerjisi ve enerji kalitesi ile ilgili çalışmalarda da büyük başarı ve doğruluk oranına sahip derin öğrenme teknikleri kullanılmaya başlanmıştır. Geleneksel olarak, özellik çıkarma ve sınıflandırma bir işaret sınıflandırma sisteminin iki ana bileşenidir, ancak derin öğrenme ile sınıflandırma ve özellik çıkarma birlikte optimize edilebilmektedir [14]. Literatürde derin evrişimli sinir ağları (CNN'ler) voltaj düşüşlerinin otomatik özellik çıkarma ve sınıflandırması için kullanılarak başarılı bir sınıflama sağlanmıştır [15]. Diğer bir çalışmada güç sistemindeki seyrek izlenen baralarda gerilim düşüşü büyüklüğü tahmini için derin CNN kullanan derin öğrenme yöntemi önerilmiştir [16]. Bununla birlikte tekrarlayan sinir ağının (RNN) özel bir durumu olan uzun kısa-süreli bellek (LSTM), voltaj düşüşlerinin özellik çıkarma ve sınıflandırması için kullanılmıştır [17]. PQD analizi için [18]'da LSTM tabanlı bir model kullanılmıştır.

Literatürdeki çalışmaların çoğunda, elektrik işaretleri öncelikle bir işaret ön işleme neticesinde 2-boyutlu ifadeler haline getirilerek derin ağ tabanlı metodlarla sınıflandırma ve tespit gerçekleştirilmektedir. Fakat, ön işleme teknikleri her ne kadar doğruluğu arttırsa da zaman ve verim açısından dezavantaja yol açabilmektedir. Bu sebeple, bu çalışmada kullanılan elektrik işaretlerinin herhangi bir ön işlemeye tabii tutulmaksızın, yalın biçimde LSTM ağına girdi olarak tanımlanması ve neticesinde hem yüksek hız hem de yüksek doğruluğun birlikte yer alabileceği bir sınıflandırma üzerine çalışılmıştır. Sunulan sonuçlar incelenirse, genel başarı oranının %83 ile %93 arasında olduğu görülebilmektedir.

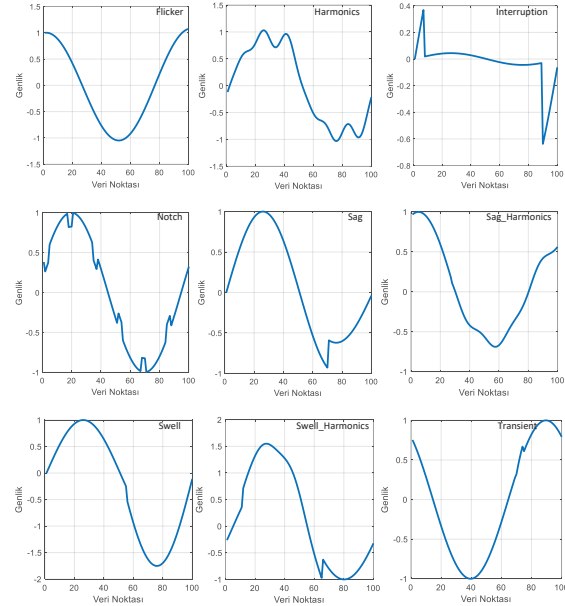
2. Veri Seti

Bu çalışmada, literatürde yayınlanmış bir PQD veri seti olan SEED Power Quality Disturbance Dataset v1 kullanılmıştır [19]. Veri setinde 17 sınıfa ait işaretler sunulmuştur. PQD işaretlerine ait sınıflar ve isimler, *Pure Sinusoidal*, *Sag*, *Swell*, *Interruption*, *Transient*, *Oscillatory Transient*, *Harmonics*, *Harmonics with Sag*, *Harmonics with Swell*, *Flicker*, *Flicker with Sag*, *Flicker with Swell*, *Sag with Oscillatory Transient*, *Swell with Oscillatory Transient*, *Sag with Harmonics*, *Swell with Harmonics*, *Notch* olarak sunulmuştur. Veri setindeki işaretlerin elde edilmesine dair özellikler Tablo 1 ile verilmiştir.

Tablo 1. PQD veri seti işaret özellikleri

Parametre	Değer
Temel Frekans	50 Hz
Örnekleme Frekansı	5 kHz
Sınıf Sayısı	17
Sınıf Başına İşaret Sayısı	1000
İşaret Vektörel Boyutu	100
İşaret Zamansal Boyutu	20 ms

Veri setinde mevcut olan PQD'lerden 10 sınıf, özellikle kendine has karakteristik gösteren sınıflar, bu çalışmada kullanılmak üzere seçilmiştir. Daha karmaşık olan ve birden fazla karakteristik içeren sınıflar seçilmemiştir. Bunlar sırasıyla; *Flicker (F)*, *Harmonics (H)*, *Interruption (I)*, *Notch (N)*, *Pure Sinusoidal (PS)*, *Sag (SG)*, *Sag with Harmonics (SGH)*, *Swell (SW)*, *Swell with Harmonics (SWH)*, *Transient (T)* sınıflarıdır. Her bir sınıfta toplam 1000 örnek mevcuttur. *PS* işareti dışında kalan 9 PQD işaretine dair örnek grafikler Şekil 1 ile sunulmuştur.



Şekil 1. PQD işaret örnek grafikleri

Bununla birlikte Eşitlik (1)-(10) ile elde edilen PQD işaretlerinin eldesi ile ilgili formülasyonlar verilmektedir [19]. Burada w ve t sayıları radyal frekans ve zamanı ifade etmektedir. Ayrıca, t_1 ve t_2 parametreleri olayın başladığı ve bittiği anı belirtmektedir. φ faz farkı ve α ise 0.9 ile 1 arasında olan zaman parametresidir.

$$F = [1 + \lambda \sin(w_f t)] \sin(wt - \varphi) \quad (1)$$

$$H = \sin(wt - \varphi) + \sum_{n=3}^7 \alpha_n \sin(nwt - \theta_n) \quad (2)$$

$$I = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(wt - \varphi) \quad (3)$$

$$N = \sin(wt - \varphi) - \text{sign}(\text{sign}(wt - \varphi)) \quad (4)$$

$$PS = \sin(wt - \varphi) \quad (5)$$

$$SG = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(wt - \varphi) \quad (6)$$

$$SGH = SG + H \quad (7)$$

$$SW = [1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(wt - \varphi) \quad (8)$$

$$SWH = SW + H \quad (9)$$

$$T = \sin(wt - \varphi) - \psi(e^{-750(t-t_a)} - e^{-344(t-t_b)})(u(t - t_1) - u(t - t_2)) \quad (10)$$

2.1. İşaretlere Gürültü Eklenmesi

Veri setinde mevcut olan elektrik işaretlerine, sınıflandırma ve tespit performansının gerçeğe daha yakın biçimde doğrulanması amacıyla da çeşitli gürültü seviyelerinde eklemeler yapılmıştır. 10db, 20db ve 40db olarak eklenen gürültüler için kullanılan ilgili formülasyon Eşitlik (11)-(14) ile verilmiştir. Burada *noise* rasgele oluşturulan bir vektörel form, *i* sayısı eleman indisi ve *n* sayısı da işaretin toplam uzunluğunu teşkil etmektedir. *NS* ve *S* değişkenleri ise gürültülü işaret ve skala faktörüdür.

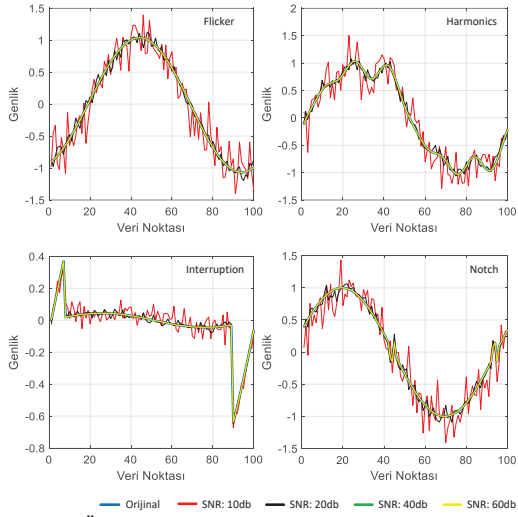
$$Power_{signal} = \sum_{i=1}^n |signal_i|^2 \quad (11)$$

$$Power_{noise} = \sum_{i=1}^n |noise_i|^2 \quad (12)$$

$$S = \left(10 \times \frac{Power_{signal}}{Power_{noise}} \right)^{\frac{-SNR}{10}} \quad (13)$$

$$NS = signal + noise \times |S| \quad (14)$$

Ayrıca, bazı örnek işaretlerin orijinal formları ve gürültülü hallerine ilişkin görseller Şekil 2 ile sunulmuştur.



Şekil 2. Örnek PQD'ler için orijinal ve gürültü eklenmiş hali

3. Yöntem


Bu çalışmada, son yıllarda zamana bağlı verilerin tahmini ve sınıflandırılması amacıyla kullanılan basit ve etkili bir yinelemeli LSTM kullanılmıştır. LSTM hem çalışma hızı hem de sayısal verilere uygun bir ağ olması sebebiyle, işaretler üzerinde herhangi bir ön işleme ihtiyacı olmadan direkt işleme alınabilmektedir. Aslında benzer bir ağ olan kapılı (geçitli) tekrarlayan birimlerden oluşan ağlar (GRU) kullanım açısından LSTM ile benzerdir ve problem özelinde daha iyi sonuç verebilir fakat, GRU'lar ve LSTM'ler kaybolan gradyan sorununu önlemek için bilginin geçişine yönelik farklı yaklaşımlar kullanır. GRU birimi, LSTM birimi gibi bilgi akışını kontrol eder, ancak bir bellek birimi kullanmak zorunda kalmaz. Bu sebeple GRU'lar LSTM'lere göre daha basit kullanım alanına sahiptir. Fakat LSTM kullanarak karmaşık problemlere özel hem girdiler hem de ileri beslemeli ağlardan farklı olarak geri bildirim özellikleri ile daha kapsamlı bir özellik çıkarımına olanak sağlarlar. LSTM ilk olarak S. Hochreiter, ve J. Schmidhuber [20] tarafından önerilmiştir.

Birimin yapısı Şekil 3 ile verilmiştir. Soldaki girişler bellek, gizli durum ve girişin bir önceki hali; sağdaki çıkışlar ise bellek ve gizli durumun şu anki halini ifade etmektedir. Bellek bilgisi, giriş bilgisi ve aday vektörü ifadeleri ise sırasıyla, F_t , I_t ve \hat{C}_t olarak gösterilmektedir. w parametresi *ağırlık*, b parametresi *yanlılık*, H *gizli durum* ve X ise *giriş* değişkenlerini ifade etmek üzere, t zaman anındaki LSTM parametrelerine ait parametreler Eşitlik (15)-(17) ile verilmiştir.

$$F_t = \sigma\{w_F \times (H, X_t) + b_F\} \quad (15)$$

$$I_t = \sigma\{w_I \times (H_{t-1}, X_t) + b_I\} \quad (16)$$

$$\hat{C}_t = \tanh\{w_C \times (H_{t-1}, X_t) + b_C\} \quad (17)$$



Şekil 3. LSTM birim mimarisini

3.1. LSTM Metodunun Uygulanması ve Sistem Parametreleri

Çalışmada, Intel® i7-10700F işlemci ve 16GB belleğe sahip bir bilgisayar kullanarak LSTM ağını eğitebilmek amacıyla Matlab yazılımı üzerindeki derin öğrenme araçları kullanılmıştır. Öncelikle LSTM mimarisini uygun biçimde tanımlanmış; daha sonra veri setindeki veriler belirli oranda eğitim, validasyon ve test olarak gruplandırılmıştır. Şekil 4 ile verilen kod bloğunda tanımlanan LSTM ağına dair bilgiler görülebilir. Burada *numHiddenUnits* LSTM birim sayısı ve *numClasses* ise eğitim yapılacak sınıf sayısını ifade etmektedir.

```
layers = [
    sequencelInputLayer(1,"Giris","input")
    lstmLayer(numHiddenUnits,"LSTM","lstm",...
    "OutputMode","last")
    dropoutLayer(0.5,"Sonumleme","dropout")
    fullyConnectedLayer(numClasses,"TamBagli","fc")
    softmaxLayer("Entropi","softmax")
    classificationLayer("Siniflama","classification")];
```

Şekil 4. LSTM sınıflayıcı tanımlaması

Katmanlar incelendiğinde, sıralı sınıflama katmanı, LSTM birimleri, sönümlenme katmanı, tam bağlı katman, entropi katmanı ve sınıflama katmanından oluştuğu görülebilir. Oluşturulan ağ mimarisinin detaylarını ifade eden şematik ise Şekil 5 ile sunulmuştur.

ANALYSIS RESULT				
Name	Type	Activations	Learnable Proper...	States
1 input	Sequence Input	1(C) × 1(B) × 1(T)	-	-
2 lstm	LSTM with 100 hidden units	100(C) × 1(B)	InputWeights: 400 × ~, RecurrentWeights: 400 × ~, Bias: 400 × ~	HiddenStates: 100 × ~, CellStates: 100 × ~
3 dropout	50% dropout	100(C) × 1(B)	-	-
4 fc	10 fully connected layer	10(C) × 1(B)	Weights: 10 × 100, Bias: 10 × 1	-
5 softmax	softmax	10(C) × 1(B)	-	-
6 classification	crossentropy	10(C) × 1(B)	-	-

Şekil 5. LSTM ağ detayları

Sınıflandırma ağı için eğitim parametreleri örnek kod bloğu Şekil 6 ile verilmiştir. Eğitim aşamasındaki optimizasyon algoritması *adam* olarak seçilmiştir. Bununla birlikte, dönem (epoch) sayısı 100; *MiniBatchSize* 64 ve *GradientThreshold* parametresi ise 2 olarak seçilmiştir. Bunun ardından *trainNetwork* komutu ile eğitim için seçilen veriler (*xTrain*, *yTrain*) ağ eğitim işlemine girdi olarak verilerek LSTM tabanlı sınıflandırma ağı belirlenen parametreler ile başarılı şekilde eğitilebilmektedir. Tek seferde işlenecek veri sayısının 64 seçilme ve dönem sayısının ise 100 seçilmesi birkaç deneme neticesinde belirlenmiştir. Yapılan ön çalışmalarda hem çalışma hızı hem de doğruluk durumu incelendiğinde belirtilen parametre değerlerinin uygun olduğu görülmüştür.

```
miniBatchSize = 64;
options = trainingOptions('adam', ...
    'ExecutionEnvironment','cpu', ...
    'MaxEpochs',100, ...
    'MiniBatchSize',miniBatchSize, ...
    'ValidationData',{xVal,yVal}, ...
    'GradientThreshold',2, ...
    'Shuffle','every-epoch', ...
    'Verbose',false, ...
    'Plots','training-progress');
[net,info] = trainNetwork(xTrain,yTrain,layers,options);
```


Şekil 6. Sınıflandırma ağı eğitim parametreleri

4. Bulgular

PQD işaretleri %70 eğitim, %15 validasyon ve %15 test olmak üzere gruplara ayrılmıştır. Sınıf başına eğitim, validasyon ve test veri sayısı sırasıyla 700, 150 ve 150 olmaktadır. Bu makalede toplam 4 farklı durum çalışması için eğitim ve test işlemleri gerçekleştirilmiştir. Bunlardan ilk iki durum çalışmasında orijinal veriler kullanılarak farklı sayıdaki sınıflar birlikte eğitilmiş; üçüncü durum çalışmasında tüm sınıflar eğitilmiştir. Son durum çalışmasında ise gürültü etmenine sahip veriler eğitim ve test işlemlerine tabii tutulmuştur.

4.1. Durum 1: Ani Gerilim Yükselmesi ve Düşüşü İçeren Sınıfların Tespiti

Bu durum çalışmasında, *Pure Sinusoidal (PS)*, *Sag (SG)*, *Sag with Harmonics (SGH)*, *Swell (SW)*, *Swell with Harmonics (SWH)* olmak üzere toplam 5 sınıf eğitim işlemine alınmıştır. Eğitim aşamasının son 500 iterasyon başarım grafiği Şekil 7 ile sunulmuştur. Eğitim ve validasyon aşamaları için genel başarı oranları sırasıyla %98.42 ve %98.26 olarak elde edilmiştir.



Şekil 7. Durum 1 için LSTM eğitim başarı grafiği


Bununla birlikte test aşamasına ait karışıklık matrisi de Şekil 8 ile verilmiştir. Karışıklık matrisi incelendiğinde, *PS* sınıfının %100 başarı ile tanımlandığı; en az başarı ile ise *SWH* sınıfı ile %95.33 olduğu görülebilmektedir. Test durumu için genel başarı oranı ise, %97.86 olarak elde edilmiştir.

Gerçek Sınıf	PS	SG	SGH	SW	SWH
PS	150				
SG	2	148			
SGH	1	1	147		1
SW	4			146	
SWH				7	143
	PS	SG	SGH	SW	SWH

Şekil 8. Durum 1 için karışıklık matrisi

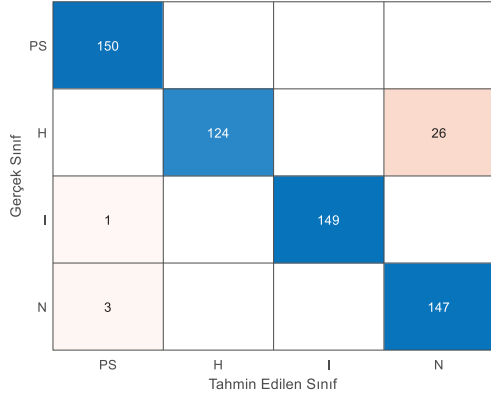
4.2. Durum 2: Sürekli ve Anlık Değişim Karakteristilerinin Tespiti

Bu durum çalışmasında, *Pure Sinusoidal (PS)*, *Harmonics (H)*, *Interruption (I)* ve *Notch (N)* olmak üzere toplam 4 sınıf üzerinden LSTM eğitimi sağlanmıştır. Eğitim aşamasının son 500 iterasyonunun başarım grafiği Şekil 9 ile sunulmuştur. Eğitim ve validasyon aşamaları için genel başarı oranları sırasıyla %97.57 ve %95.33 olarak elde edilmiştir. Grafik incelendiğinde 200. veri noktasında doğruluk oranının %75'lere düşmesi durumu gözlenmiştir. Bu ve benzer durumlar eğitim parametrelerinde 64 olarak seçilen *minibatchsize* parametresi ile ilgilidir. Yani her bir veri noktasında o an rasgele seçilen 64 örneklem için başarı oranı görülmektedir.




Şekil 9. Durum 2 için LSTM eğitim başarı grafiği

Bu durum çalışmasındaki test aşamasına ait karışıklık matrisi Şekil 10 ile verilmiştir. Karışıklık matrisi incelendiğinde, *PS* sınıfının %100 başarı ile tanımlandığı; en az başarı ile ise *H* sınıfı ile %82.62 olduğu görülebilmektedir. Test durumu için genel başarı oranı ise, %95.00 olarak elde edilmiştir.




Şekil 10. Durum 2 için karışıklık matrisi



Şekil 12. Durum 3 için karışıklık matrisi

4.3. Durum 3: Tüm Sınıfların Orijinal İşaretler Üzerinden Eğitilmesi ve Tespiti

Bu durum çalışmasında, Bölüm 2'de çalışma kapsamında seçildiği belirtilen 10 sınıf orijinal işaretler üzerinden tespitine yönelik benzetimler sağlanmıştır. Bu sınıflar, *Flicker (F)*, *Harmonics (H)*, *Interruption (I)*, *Notch (N)*, *Pure Sinusoidal (PS)*, *Sag (SG)*, *Sag with Harmonics (SGH)*, *Swell (SW)*, *Swell with Harmonics (SWH)*, *Transient (T)* sınıflardır. Eğitim aşamasının son 500 iterasyonunun başarım grafiği Şekil 11 ile sunulmuştur. Eğitim ve validasyon aşamaları için genel başarı oranları sırasıyla %87.70 ve %81.86 olarak elde edilmiştir.




Şekil 11. Durum 3 için LSTM eğitim başarı grafiği

Bu durum çalışmasındaki test aşamasına ait karışıklık matrisi Şekil 12 ile verilmiştir. Karışıklık matrisi incelendiğinde, *PS* sınıfının %100 başarı ile tanımlandığı; en az başarı ile ise *H* sınıfı ile %50.66 olduğu görülebilmektedir. Test için genel başarı oranı ise, %80.00 olarak elde edilmiştir.

Test edilen veriler incelendiğinde *H*, *N* ve *T* sınıflarının diğerlerine nazaran daha düşük başarımda olduğu görülmekle birlikte, en çok karıştırılan sınıf *H* ve *N* sınıfları ile *N* ve *T* sınıfları olmuştur. Dolayısıyla verilen bu 3 sınıf dışındaki sınıfların başarı oranı %89.04 olarak hesaplanabilmektedir ve bunun başarılı bir doğruluk oranını ifade ettiği görülebilir.

4.4. Durum 4: Tüm Sınıfların Gürültü Eklenmiş İşaretler Üzerinden Eğitilmesi ve Tespiti

Bu durum çalışmasında, Bölüm 2'de çalışma kapsamında seçildiği belirtilen 10 sınıfın 10db, 20db, 40db ve 60db olarak gürültü eklenmiş işaretler üzerinden tespitine yönelik benzetimler sağlanmıştır. Eğitim aşamalarının son 100 iterasyonunun başarım grafiği Şekil 13 ile sunulmuştur. Eğitim ve validasyon aşamaları için genel başarı oranları sırasıyla 10db gürültü için %77.34 ile %68.60; 20db gürültü için %84.70 ile %78.27, 40db gürültü için %89.40 ile %85.20 ve 60db gürültü için %81.25 ile %80.65 olarak elde edilmiştir.



Şekil 13. Durum 4 için LSTM eğitim grafiği

Bu durum çalışmasındaki test aşamasına ait karışıklık matrisleri Şekil 14.a, Şekil 14.b, Şekil 14.c ve Şekil 14.d ile verilmiştir. Veriler incelendiğinde, *PS* sınıfının 20db ve 40db gürültülü işaretler için %100 başarı ile tanımlandığı fakat 10db gürültülü işaretler için ise %93.33 başarı oranı sağladığı görülebilmektedir.

Bununla birlikte, 10db, 20db, 40db ve 60db gürültü oranları için en düşük sınıflama başarı sırasıyla *H*, *T*, *N* ve *H* olarak %16, %32, %59.33, ve %50.66 başarı oranı ile elde edilmiştir. En çok karıştırılan sınıflar ise ilk durum çalışması için *F* ve *H* ve diğer 3 durum çalışması için *H* ve *T* olmuştur.

Test durumları için genel başarı oranları 10db, 20db, 40db ve 60db için sırasıyla; %65.20, %76.60, %83.13 ve %80.27 olarak elde edilmiştir.

Gerçek Sınıf	F	H	I	N	PS	SG	SGH	SW	SWH	T
F	120	4			3			4	6	13
H	77	24		14	5				1	29
I			127		1	14	8			
N	32	23		52	9		3	1		30
PS					140				10	
SG			6		17	118	9			
SGH		1	3	16	1	8	117			4
SW					11			139		
SWH	33	5						10	101	1
T	74	14		16	6					40

Tahmin Edilen Sınıf

Şekil 14.a. Durum 4: 10db gürültü altındaki test verisi için karışıklık matrisi

Gerçek Sınıf	F	H	I	N	PS	SG	SGH	SW	SWH	T
F	117	30						1		2
H	3	80		11	4					52
I			148		1	1				
N		28		93	3	1	9			16
PS					150					
SG			7		4	139				
SGH		1		7	1	6	134			1
SW	3	1			7			139		
SWH	29	9						9	101	2
T		71		28	3					48

Tahmin Edilen Sınıf

Şekil 14.b. Durum 4: 20db gürültü altındaki test verisi için karışıklık matrisi

Gerçek Sınıf	F	H	I	N	PS	SG	SGH	SW	SWH	T
F	136	1						3	10	
H	13	110		3	3			1		20
I			145		1	3	1			
N	2			89	4	2	4			49
PS					150					
SG			8		4	138				
SGH		1		12	1	5	127			4
SW					6			144		
SWH	20	6						9	115	
T	2	52		3						93

Tahmin Edilen Sınıf

Şekil 14.c. Durum 4: 40db gürültü altındaki test verisi için karışıklık matrisi

True Class	F	H	I	N	PS	SG	SGH	SW	SWH	T
F	145	1							3	1
H	5	76		4					1	64
I			135		1	14				
N		3		85	2	1	3			56
PS					150					
SG			13		3	134				
SGH		1	2	23	1	4	117			2
SW					6			144		
SWH	22	4						7	115	2
T		43		2	2					103

Predicted Class

Şekil 14.d. Durum 4: 60db gürültü altındaki test verisi için karışıklık matrisi

4.5. Elde Edilen Sonuçların Analizi ve Karşılaştırılması


Yapılan çalışmada elde edilen sonuçlara dair veriler toplu halde Tablo 2 ile sunulmuştur. Görülmektedir ki çalışılan sınıf sayısı arttıkça genel başarı oranı ve bazı sınıfların başarı oranları düşüş gösterebilmektedir. Bununla birlikte, durum çalışmaları 1 ve 2 incelenirse, işlenen sınıf sayısı azalmasına rağmen başarı oranı da düşüşte olduğu görülebilmektedir. Bunun en büyük sebebi ise tüm durum çalışmalarında en düşük başarı oranına sahip olan H, N ve T sınıflandır.

Bununla birlikte Şekil 8 ve Şekil 12 ile verilen karışıklık matrisleri karşılaştırılırsa, Durum 1'de en düşük başarı oranına sahip olan SWH sınıfının doğruluğu %95.33 iken Durum 3'te %76.00 başarı oranına düşmüştür. Bunun sebebi ise ilk durum çalışmasında 5 sınıf eğitilirken diğerinde 10 farklı sınıf eğitimi sağlanmıştır. Bunun yanı sıra test sonuçlarına ait ortalama karekök hatası (RMSE) değerleri de hesaplanmış ve tabloda sunulmuştur. Sınıf sayısının 5 olarak seçildiği ilk durum çalışmasında RMSE değeri 0.2683 ile en iyi sonucu verirken, 10db gürültülü ve 10 sınıf içeren çalışmada ise 3.2717 değerine sahiptir. Ayrıca, toplu halde çalışılan dosyalar için işaret başına sınıflama zamanı üzerinde durulursa, tek bir işaretin 0.154 ile 0.165 ms'lik süreler arasında sınıflanabildiği görülebilmektedir. Ayrıca, bu çalışmada elde edilen sonuçlara ait eğitim ve test sürelerine ait başarı oranları ve RMSE değerleri Şekil 15 ile sunulmuştur.

Bununla birlikte Tablo 2 ile verilen ve literatürde yapılan diğer çalışmalara ait sonuçlar incelendiğinde, 8 adet sınıf içeren bir çalışmada %98.30 test başarı oranının elde edildiği; 9 sınıf içeren başka bir çalışmada %100 başarı oranının elde edildiği tespit edilmiştir. [12] ve [19] ile verilen çalışmalarda ise sırasıyla 15 ve 17 adet sınıf içeren çalışmalarda sırasıyla %99 ile %96.50 arasında test başarı oranının elde edildiği görülebilmektedir. Sunulan bu çalışmalardan birinde 34.99ms zaman ile verilen bir sınıflandırma zamanı sunulmuştur. Bu sürenin tek bir işaret için mi yoksa birden fazla işaretin toplu halde sınıflandırılmasına mı ait olduğu belirtilmemiştir. Fakat [19] ile bu makalede yapılan sınıflandırma metodlarının süre açısından karşılaştırılırsa, büyük bir zaman farkı ile sınıflandırmanın gerçekleştirildiği söylenebilir. Kullanılan LSTM ağının parametre sayısı, ağız kendi dinamik hızı ve diğer etmenler dikkate alındığında, %83.13'lük bir başarı oranı ve 0.157ms tek işareti sınıflandırma süresinin diğer çalışmalar arasında kabul edilebilirliğinin olduğu düşünülmektedir.

Tablo 2. Durum çalışmalarının karşılaştırılması

Çalışma	Sınıf Sayısı	Başarı Oranı (%)		RMSE	Zaman (ms)
		Eğitim	Test		
[10]	8	-	98.30	-	-
[11]	9	-	100	-	-
[12]	15	-	99.00	-	-
[19]	17	-	96.50	-	34.99
Durum1	5	98.42	97.86	0.2683	0.160
Durum2	4	97.57	95.00	0.4301	0.165
Durum3	10	87.70	80.00	2.7737	0.154
Durum4.1 (10db)	10	77.34	65.20	3.2717	0.155
Durum4.2 (20db)	10	84.70	76.60	2.9207	0.161
Durum4.3 (40db)	10	89.40	83.13	2.5138	0.157
Durum4.4 (60db)	10	81.25	80.27	2.7708	0.160



Şekil 15. Tüm durumlara ait başarı oran ve metrikleri

5. Sonuçlar

Elektrik enerji kalitesi odaklı bu çalışmada, güç kalite bozulmaları ile ilgili olaylardan bazıları derin öğrenme ağlarından olan LSTM tabanlı bir sınıflayıcı ile eğitilmiş ve tespiti sağlanmıştır. Yapılan sınıflama çalışmalarında yüksek başarı ve doğruluk oranının elde edildiği tespit edilmiştir. Ayrıca işaret başına yaklaşık 0.16 milisaniye tahmin ve sınıflama süresi ile gayet kısa bir sürede işlem yapılması da bu tip sistemlerin gerçek zamanlı olarak kullanılabilirliği açısından da gelecek vaat etmektedir. Günümüzde kişisel bilgisayarlar kullanarak dahi bu tip işlemler ve sistemlerin oluşturulması, tasarımı ve uygulaması gayet yerinde ve faydalı olabilecektir. Bu çalışmada,

1. Literatürde sunulan bir veri seti kullanılarak yapılan bu çalışmada, ani gerilim düşüş ve artışı içeren sınıflar üzerinde %97.86'lık bir doğruluk oranı 0.2683 ortalama karekök hatası ile elde edilmiştir.

2. Bunun yanı sıra, veri setinde sunulan işaretlere çeşitli rasgele gürültü işaretleri de eklenerek yapılan alt durum çalışmalarında %65.20 ila %83.13 arasında test başarımları görülmüştür.
3. Tahmin ve sınırlandırma süresinin de birçok standartta yer alan maksimum sürelerin daha altında olduğu görülebilmektedir.

Kaynaklar

- [1] B. Eristi, V. Yamacli, H. Eristi "A Novel Microgrid Islanding Classification Algorithm Based on Combining Hybrid Feature Extraction Approach with Deep Resnet Model", *Electrical Engineering*, 106, 145-164, 2024.
- [2] R.C. Dugan, M.F. McGranaghan, S. Santoso, H.W. Beaty, *Electrical Power System Quality*, McGraw Hill, 2002.
- [3] E. Fuchs, M.A.S. Masoum, *Power Quality in Power System and Electrical Machines*, Academic Press, 2008.
- [4] M.H.J. Bollen, I.Y.H. Gu, *Signal Processing of Power Quality Disturbances*, Wiley, New York, 2006.
- [5] B. Biswal, P.K. Dash, B.K. Panigrahi, "Non-Stationary Power Signal Processing for Pattern Recognition Using HS-Transform", *Applied Soft Computing*, 9(1), 107-117, 2009.
- [6] W.G. Morsi, M.E. El-Hawary, "Novel Power Quality Indices Based on Wavelet Packet Transform for Non-Stationary Sinusoidal and Non-Sinusoidal Disturbances", *Electrical Power System Research*, 80(7), 753-759, 2010.
- [7] IEEE Std. 1159, *IEEE Recommended Practices for Monitoring Electric Power Quality*, 1995.
- [8] European Standard E.N. 50160, *Voltage Characteristics of Electricity Supplied by Public Distribution Systems*, 2002.
- [9] IEEE Standard for Interconnecting Distributed Resources with Electric Power Systems, *IEEE Standard 1547-2003*, 2003.
- [10] K. Manimala, K. Selvi, R. Ahila, "Optimization Techniques for Improving Power Quality Data Mining Using Wavelet Packet Based Support Vector Machine", *Neurocomputing* 77(1), 36-47, 2012.
- [11] M. Lopez-Ramirez, L. Ledesma-Carrillo, E. Cabal-Yepez, C. Rodriguez-Donate, H. Miranda-Vidales, A. Garcia-Perez, "EMD-Based Feature Extraction for Power Quality Disturbance Classification Using Moments", *Energies* 9(7), 565, 2016.
- [12] J. Wang, Z. Xu, Y. Che, "Power Quality Disturbance Classification Based on Compressed Sensing and Deep Convolution Neural Networks", *IEEE Access*, 7, 78336-78346, 2019.
- [13] M. Gok, I. Sefa, "Research and Implementation of A USB Interfaced Real-Time Power Quality Disturbance Classification System", *Advances in Electrical and Computer Engineering*, 17(3), 61-70, 2017.
- [14] X. Wang, *Deep Learning in Object Recognition, Detection, and Segmentation*, Now, 2016.
- [15] A. Bagheri, I.Y.H. Gu, M.H.J. Bollen, E. Balouji, "A Robust Transform-Domain Deep Convolutional Network for Voltage Dip Classification", *IEEE Transactions on Power Delivery*, 33, 2794-2802, 2018.

- [16] H. Liao, J.V. Milanovi'c, M. Rodrigues, A. Shenfield, "Voltage Sag Estimation in Sparsely Monitored Power Systems Based on Deep Learning and System Area Mapping", IEEE Transactions on Power Delivery, 33, 3162–3172, 2018.
- [17] E. Balouji, I.Y.H. Gu, M.H.J. Bollen, A. Bagheri, M. Nazari, "A LSTM-Based Deep Learning Method with Application to Voltage Dip Classification", 2018 18th International Conference on Harmonics and Quality of Power (ICHQP), 2018, 1–5.
- [18] Y. Deng, H. Jia, P. Li, X. Tong, F. Li, "A Deep Learning Method Based on Long Short-Term Memory and Sliding Time Window for Type Recognition and Time Location of Power Quality Disturbance", 2018 Chinese Automation Congress (CAC), 2018, 1764–1768.
- [19] M.U. Khan, S. Aziz, A. Usman, "XPQRS: Expert Power Quality Recognition System for Sensitive Load Applications", Measurement, 216, 112889, 2023.
- [20] S. Hochreiter, ve J. Schmidhuber, "Long Short-Term Memory", Neural Computation, 9(8), 1735-1780, 1997.

Özgeçmişler



Volkan YAMAÇLI, 1987 yılında Tarsus'ta doğmuştur. 2014 yılında "FACTS Cihazları İçeren Güç Sistemlerinin Sezgisel Algoritmalarla Optimizasyonu" üzerine yaptığı Tez çalışmasıyla Mersin Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Yüksek Lisans Programından mezun olmuştur. 2021 yılında "Şebekeye Bağlı Modüler Çok Seviyeli Dönüştürücü İçeren Yüksek Gerilim Doğru Akım İletim Sistemlerinin Kontrol ve Optimizasyonu" başlıklı Tez çalışmasıyla Mersin Üniversitesi Fen Bilimleri Enstitüsü'nden Elektrik-Elektronik Mühendisliği alanında Doktora Derecesi ile mezun olmuştur. 2011-2021 yılları arasında Mersin Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümünde Araştırma Görevlisi olarak görev yapmıştır. 2021 yılından bugüne Mersin Üniversitesi, Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nde Dr. Öğretim Üyesi olarak görev yapmaktadır. 2024-2025 ders yılı itibarıyla MEÜ Bilgisayar Mühendisliği Bölümü'nde Bölüm Başkan Yardımcısı olarak görev yapmaktadır. Mevcut araştırma ve ilgi alanları arasında hibrit güç ve enerji sistemleri, enerji kalitesi ve optimizasyonu üzerine derin öğrenme ve yapay zekâ çözümleri yer almaktadır.