



Metasezgisel Tabanlı Özellik Seçim Algoritmalarının Güç Kalitesi Olaylarının Sınıflandırılmasına Etkisinin İncelenmesi

Analysing the Effect of Metaheuristic Based Feature Selection Algorithms on the Classification of the Power Quality Events

Birsen Gümüş¹, Melih Çoban², Süleyman Sungur Tezcan^{1*}

¹Gazi Üniversitesi Mühendislik Fakültesi, Elektrik-Elektronik Müh.Böl., 06570, Ankara, TÜRKİYE

²Bolu Abant İzzet Baysal Üniversitesi Mühendislik Fakültesi, Elektrik-Elektronik Müh.Böl., 14030, Bolu, TÜRKİYE

Başvuru/Received: 22/01/2024 Kabul/Accepted: 29/02/2024 Çevrimiçi Basım/Published Online: 30/06/2024
Son Versiyon/Final Version: 30/06/2024

Öz

Bu çalışmada, güç kalitesi bozulmalarının sınıflandırmasında önemli bir role sahip olan özellik seçme aşaması için iki farklı optimizasyon algoritması kullanılmıştır. Çalışmanın birinci kısmında, sınıflandırma sürecinin başlaması için güç kalitesi olaylarını içeren sinyaller üretilmiştir. Özellik çıkarma için Ayırık Dalgacık Dönüşümü (DWT) kullanılmıştır. Özellik çıkarma işleminden sonra elde edilen veri seti, normalize edilerek ve logaritması alınarak iki farklı veri seti elde edilmiştir. Özellik seçme işlemi için Denge Optimize Edici Algoritması (EO) ve Salp Sürü Optimizasyon Algoritması (SSA) olarak isimlendirilen metasezgisel tabanlı optimizasyon algoritmaları özellik seçme algoritmaları olarak kullanılmıştır. Sınıflandırma için K En Yakın Komşu Algoritması (KNN) tercih edilmiştir. En yüksek sınıflandırma doğruluk oranı, özellik seçme algoritması olarak EO ve veri seti olarak logaritmik veri setinin kullanıldığı durumda, %96.05 olarak elde edilmiştir. En düşük sınıflandırma doğruluk oranı ise özellik seçme algoritmasının SSA olduğu ve normalize veri setinin kullanıldığı durumda, % 90.62 olarak elde edilmiştir. Çalışmanın ikinci kısmında ise, birinci kısımda en çok seçilen özellikleri tespit etmek için histogram grafiği oluşturulmuştur. En çok seçilen sekiz özellik ile sınıflandırma işlemi tekrarlanmıştır. Histogram grafiği kullanılarak yapılan sınıflandırmaya ilişkin elde edilen en yüksek doğruluk oranı % 95.8 ve en düşük doğruluk oranı % 93.83 olarak gözlenmiştir.

Anahtar Kelimeler

“Güç kalitesi olayları, Sınıflandırma, Makine öğrenmesi”

Abstract

In this study, two different optimization algorithms have been used for the feature selection stage, which plays a crucial role in the classification of power quality disturbances. In the first part of the study, signals containing power quality events were generated to initiate the classification process. Discrete wavelet transform (DWT) has been used for feature extraction. Two different datasets were obtained by normalizing and taking logarithm of the dataset obtained after the feature extraction process. The Equilibrium Optimizer (EO) and the Salp Swarm Optimization Algorithm (SSA), which are named metaheuristic based feature selection algorithms, were used for the feature selection process. The K Nearest Neighbour Algorithm (KNN) is preferred for classification. The highest accuracy rate in classification was achieved at 96.05% when utilizing EO as the feature selection algorithm and using the logarithmic dataset. The lowest classification accuracy rate was obtained as 90.62% when the feature selection algorithm was SSA and the normalized data set was used. In the second part of the study, a histogram graph was created to identify the most frequently selected features from the first part. The highest accuracy rate obtained for the classification using the histogram graph was observed to be 95.8% and the lowest accuracy rate was 93.83%.

Key Words

“Power quality events, Classification, Machine learning”

1.Giriř

Güç kalitesi terimi, üretilen enerjinin gerilim, akım ve frekans karakteristik deęerlerinde bir deęişiklik olmadan veya ideal dalga formunda kullanıcıya iletilebilmesi şeklinde tanımlanmaktadır (Darrow vd., 2005,s.ES1). Ark ocakları, güç elektronięi cihazları, deęişken frekanslı sürücüler (VFDs) ve esnek akım iletim cihazları (FACTS) gibi lineer olmayan yükler, sürdürülebilir enerji kaynakları ve bunlara benzer dięer yükler güç kalitesi bozulmalarına sebep olmaktadır (Khetarpal & Tripathi, 2020). Güç kalitesi bozuklukları aynı zamanda güç kalitesi olayları olarak da adlandırılırlar. Bu olaylardan bazıları gerilim çökmesi, gerilim yükselmesi, harmonikler, kesintiler, kırpıřma (flicker), ve gerilim dalgalanmaları şeklinde sıralanabilir (Abdoos vd., 2016). Elektrik sistemlerinde meydana gelen tek faz toprak arası kısa devre (SLG), iki faz arası kısa devre (LL), iki faz toprak kısa devre (LLG), ve üç faz simetrik kısa devre LLL) arızaları gerilim çökmesi, gerilim yükselmesi ve anlık kesintilere sebep olurken, gerilim dalgalanmaları genellikle ark ocaklarından kaynaklanır. Harmonikler ve kırpıřma gibi sürekli durum dalga bozulmaları ise güç elektronięi dönüřtürücülerini ve doęrusal olmayan yüklerin kullanılmasıyla ortaya çıkmaktadır. Güç aęlarındaki geçici ve anlık bozulmalar ise büyük yüklerin ani kapatılması ya da yıldırım gibi nedenlerle ortaya çıkmaktadır (Khokhar vd., 2017). Güç kalitesi olaylarının en kısa sürede belirlenmesi, sınıflandırılması, bunlara göre çözüm üretilerek zamanında giderilmesi sistemlerin kesintisiz ve düzgün çalışması açısından aynı zamanda ekonomik açıdan da önemlidir (Sharma vd., 2018; Edomah, 2010). Bu yüzden son yıllarda güç kalitesi sınıflandırılmasına iliřkin çalışmalar hızla artmaktadır (Eriřti vd., 2013). Güç kalitesi bozukluklarının tespiti ve sınıflandırılması ařama ařama gerçekleşen bir süreçtir. Bu aşamalar özellik çıkarma, özellik seçme ve sınıflandırma şeklinde ilerler ve Şekil 1’de gösterilmiştir.



Şekil 1. Güç kalitesi olaylarının sınıflandırılma aşamaları

Özellik çıkarma adımı sınıflandırma başarısı açısından kritik bir adımdır ve daha iyi işleme ve bilgi alımı için ayrıştırma işleminden sonra sinyaldeki ayırt edici özellikleri belirleyerek bir özellik vektörü oluşturma işlemidir (Uyar, 2008:59-62; Khetarpal & Tripathi, 2020). Literatürde Fourier dönüşümü (FT) , dalgacık dönüşümü (WT) , Hilbert Huang Dönüşümü (HHT) , Stockwell dönüşümü (ST) gibi metotlar özellik çıkarma için sıklıkla kullanılan yöntemlerdendir (Lee & Dash,2003; Dash vd.,2003; He vd.,2013; Tse vd.,2012; Afroni vd.,2013; Karimi vd.,2000). FT tabanlı teknikler sinyali sadece frekans alanında analiz eder ve duraęan sinyallerin özelliklerini çıkarma konusunda kullanışlı iken, WT tabanlı teknikler ise sinyali hem frekans hem zaman alanında analiz eder ve duraęan olmayan sinyaller için verimlidir(Nashad,2017; Abdoos vd.,2016). Sınıflandırma sürecinin ikinci aşaması özellik seçme, sınıflandırma başarısını artırmak için özellik vektöründen en alakasız özellikleri kaldırmak ve en belirleyici özellikleri seçmek için kullanılan önemli bir adımdır. Başka bir deyişle bu adımın sonrasında sınıflandırma daha karakteristik özelliklerle ve daha küçük bir veri seti ile başlar (Mafarja, & Mirjalili,2018). Özellik seçme için kullanılan yaklaşımlar filtreleme, sarmal ve gömülü (hem filtre hem sarmal) olmak üzere üç kategoriye ayrılır. Filtreleme yaklaşımında özellik seçme herhangi bir öğrenme algoritmasından bağımsızdır ve özellikler sınıflar arası kriterlere göre seçilirler. Sarmal yaklaşımın temel fikri, daha sonra öğrenme için kullanılacak aynı öğrenme algoritması temelinde bir özellik alt kümesi seçmektir. Gömülü yaklaşımda ise özellik seçme ve sınıflandırma birbirine geçmiştir, önceki iki yaklaşımın aksine özellikler model eğitimi sırasında seçilir ve ön işlem süreci yoktur (Saunders vd., 2005:85-91). Son olarak süreç sınıflandırma aşamasıyla sonlanır. Güç kalitesi olayları destek vektör makineleri (Abdoos vd., 2016; Moravej vd., 2009), yapay sinir aęı (Valtierra-Rodriguez vd., 2014), bulanık mantık (Bih, 2006), derin öğrenme tabanlı metotlar (Balouji vd., 2018), ve karar aęaçları (Biswal & Parida, 2022) gibi yöntemlerle sınıflandırılırlar.

Bu çalışmanın temel amacı güç kalitesi olaylarının sınıflandırılmasında metasezgisel tabanlı özellik seçme algoritmaları olan EO ve SSA’ nın performanslarını karşılaştırmaktır. Bu nedenle yapılan çalışma literatürde bulunan dięer çalışmalarla karşılaştırılmayıp kendi içinde deęerlendirilmiştir. Sınıflandırma işleminde kullanılan veri seti çalışmaya özgü olarak üretilmiş olup, hali hazırda kullanılan bir veri seti deęildir. Bu kapsamda çalışmanın ilk bölümünde, bir tanesi saf sinüs sinyali olmak üzere 9 adet sentetik güç kalitesi olayı içeren sinyal üretilmiştir. Güç kalitesi olayları Matlab 2022/a yazılım programında oluşturulmuştur ve parametreler farklılaştırılarak, her bir olay için 150 adet sinyal üretilmiştir. Sonraki aşamada DWT yöntemi kullanılarak, sinyaller 6 seviyede ve 5 farklı ana dalgacık kullanılarak ayrıştırılmıştır. Enerji deęerleri alınarak her bir sinyal için özellik vektörü çıkartılmıştır. Elde edilen özellik vektörlerinden 1350*30 boyutlu bir veri seti elde edilmiştir. Veri seti hem normalize edilerek hem de logaritması alınarak iki farklı veri seti oluşturulmuştur. EO ve SSA tabanlı özellik seçme algoritmaları kullanılmıştır. Her iki algoritma da ayrı ayrı her iki veri seti ile en etkili özellikleri seçme amacıyla 30 kez çalıştırılmıştır ve her özellik seçme sonunda KNN kullanılarak sınıflandırma

tamamlanmıştır. Hangi algoritma ile hangi veri setinin en yüksek ve en düşük sonucu verdiği kıyaslanmıştır. Çalışmanın ikinci bölümünde, birinci bölümde seçilen özelliklerin seçilme sayılarını belirlemek amacıyla histogram grafikleri çıkartılmıştır. En çok seçilen sekiz özellik kullanılarak yeniden sınıflandırma işlemi yapılmıştır. Bunun sonucunda histogram grafiği kullanılarak yapılan sınıflandırma doğruluk oranının arttığı gözlenmiştir.

Çalışmanın ana katkıları aşağıda özetlenmiştir;

- 1- Üretilen sentetik sinyallerin özellikleri 5 farklı ana dalgacık kullanılarak DWT yöntemi yardımıyla çıkartılmıştır.
- 2- EO ve SSA tabanlı özellik seçme algoritmaları kullanılarak, elde edilen özellikler arasında sınıflandırma için en uygun özellikler seçilmiştir.
- 3- EO ve SSA tabanlı özellik seçme algoritmaları metasezgisel tabanlı oldukları için 30 farklı kez çalıştırılarak en çok seçilen 8 özellik kullanılarak sınıflandırma işlemi yapıp, doğruluk oranları analiz edilmiştir.

2. Metotlar

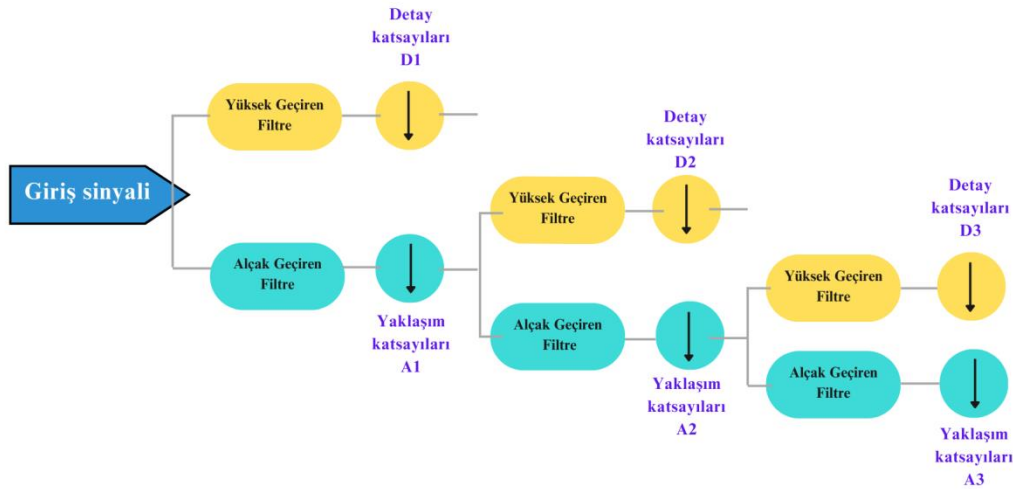
2.1 Ayırık Dalgacık Dönüşümü

DWT güç sistemlerinde sıklıkla kullanılan bir sinyal analiz yöntemidir. Bununla ilgili ilk çalışmayı Haar 1909 yılında yapmıştır. Dalgacık dönüşümü, bir ana dalgacığın ölçeğini ve genişliğini ayarlayarak zaman ve frekans alanında orijinal sinyali simüle etme işlemidir. DWT yöntemi sürekli dalgacık dönüşümü ve ayırık dalgacık dönüşümü olmak üzere ikiye ayrılır. Sürekli dalgacık dönüşümü daha kullanışlı olmasına rağmen, DWT daha az hesaplama yükü gerektirdiğinden daha çok tercih edilmektedir ve DWT bir $v(x)$ sinyali için aşağıdaki eşitlik ile ifade edilir (Fikri & El-Sayed,1988).

$$DWT_{\rho}v(a, b) = \int_{-\infty}^{\infty} v(x)\rho_{a,b}(x)dx \quad (1)$$

Burada ρ ana dalgacıktır (Mallat, 1989).

DWT yöntemi, giriş sinyalini düşük ve yüksek frekans bileşenlerine ayırmak için bir filtre serisi kullanılarak gerçekleştirilir (Salat & Osowski, 2004). Alçak ve yüksek geçiren filtreler vasıtası ile sinyallerin yaklaşım ve detay katsayıları elde edilir. Alçak geçiren filtreler yaklaşım katsayılarını (A_j) üretirken, yüksek geçiren filtreler detay katsayılarını (D_j) üretir. Yaklaşım katsayıları sinyalin alçak frekans bileşenlerini temsil ederken, detay katsayıları ise yüksek frekans bileşenlerini temsil etmektedir (Coban & Sungur,2021). DWT’ de filtre serisi yaklaşım katsayıları üzerinden ilerlemektedir ve bu n seviyede gerçekleştirilebilir. Böylece her seviyede sinyal daha dar bantlara ayrıştırılmış olacağından, DWT katsayıları eşit olmayan frekans aralıklarını temsil etmiş olur. 3 seviyeli bir DWT blok diyagramı Şekil 2’de gösterilmiştir.



Şekil 2. Ayırık Dalgacık Dönüşümü (Coban & Sungur,2021)

DWT’ de kullanılan ve ana dalgacık olarak adlandırılan fonksiyonlar vardır. Haar, Daubechies, Symlet, Coiflet, Biorthogonal literatürde sıklıkla kullanılan ana dalgacıklardır. Her ana dalgacığın özelliği farklı olduğundan bunların seçimi de sinyal ayrıştırmada önemli rol oynamaktadır (Erişti vd.,2013; Upadhy vd., 2022).

2.2. Denge Optimizasyon Algoritması

Bu algoritma Faramarzi ve arkadaşları tarafından 2020 yılında geliştirilmiştir. EO fizikteki denge unsurundan esinlenerek ortaya çıkmıştır. Bu algoritmanın yaklaşımını, bir kontrol hacmindeki reaktif olmayan bir bileşenin konsantrasyonunu tanımlamak için kütle dengesi eşitliklerinin kullanıldığı bir model oluşturur. Bu model, çeşitli kaynak ve havuz mekanizmalarının bir fonksiyonu olarak

kontrol hacmindeki konsantrasyonları hesaplamak için basit ve iyi karıştırılmış bir dinamik kütle denge eşitliği içerir (Faramarzi, 2020). Kütle denge eşitliği aşağıdaki gibidir;

$$V \frac{dC}{dt} = QC_{eq} - QC + G \quad (2)$$

Burada C , kontrol hacmindeki (V) konsantrasyonu, Q , giren ve çıkan hacimsel akış hızını, $V \frac{dC}{dt}$, kontrol hacmindeki kütle değişim oranını, C_{eq} denge durumundaki konsantrasyonu ve G kontrol hacmi içindeki kütle üretim hızını tanımlar. $V \frac{dC}{dt}$ değerinin sıfır olması denge durumuna ulaşıldığını gösterir. Kontrol hacmindeki birikimi çözmek için eşitlik (2)'in her iki tarafının integrali alınır ve zamana bağlı bir eşitlik elde edilir.

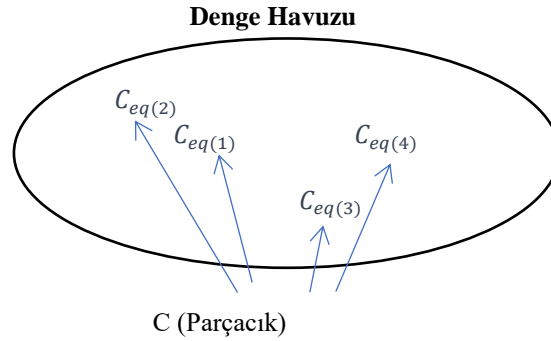
$$C = C_{eq} + (C_0 - C_{eq})F + \frac{G}{\lambda V}(1 - F) \quad (3)$$

$$F = \exp[-\lambda(t - t_0)] \quad (4)$$

Burada C_0 ve t_0 sırasıyla başlangıç konsantrasyonunu ve zamanını göstermektedir. Eşitlik (3) göstermektedir ki, her parçacık konsantrasyonunu üç durum ile güncellemektedir. İlk terim denge havuzundan rastgele seçilen ve o ana kadarki en iyi çözüm olarak kabul edilen denge konsantrasyonudur. İkinci terim bir parçacık ve denge durumu arasındaki farkı gösterir ve arama aracı görevi yapacaktır. Üçüncü terim üretim hızı ile ilgilidir ve üretim hızı en iyi çözümü bulmada ya da durumu en verimli şekilde kullanmada (sömürü) önemli rol oynar (Faramarzi, 2020).

2.3. Denge Optimizasyon Algoritması İle Özellik Seçme

EO' da parçacıklar, denge havuzundan rastgele seçilen bir adayın rehberliğinde global optimuma doğru hareket ederler. Bu ifade, her parçacığın güncelleme sürecinde rasgele seçilmiş bir adaydan öğrenme gerçekleştirdiği anlamına gelir. Eğer bu aday yerel bir optimumda takılı kalırsa, parçacığın umut vadeden bölgeleri bulma konusunda zorluk yaşama olasılığı vardır. Bu durumda performans düşecektir. Algoritmanın performansını artırmak için başka bir versiyonu geliştirilmiştir. Bu versiyona Genel Öğrenme Denge Optimizasyonu (GLEO) adı verilir. GLEO, parçacıkların farklı boyutlardaki potansiyel adaylardan öğrenmelerini sağlayan genel bir öğrenme stratejisi kullanır. Bu, algoritmanın yerel optimumdan kaçınmasına ve daha umut vadeden bölgeleri keşfetmesine yardımcı olabilir (Too & Mirjalili, 2021). GLEO' nun temel yapısı Şekil 3'te verilmiştir.



Şekil 3. Genel öğrenme denge algoritmasının temel yapısı (Too & Mirjalili, 2021)

Genel öğrenme stratejisinde parçacık aşağıdaki şekilde güncellenir;

$$C^d = C_{feq(d)}^d + (C^d - C_{feq(d)}^d)F + \frac{G}{\lambda V}(1 - F) \quad (5)$$

$$G = G_0F = (GCP(X_{feq(d)}^d - \lambda C^d)) \cdot F \quad (6)$$

$feq = [feq(1), feq(2), \dots, feq(D)]$ parçacığın hangi adayı takip etmesi gerektiğini tanımlar.

Genel öğrenme denge optimizasyon algoritmasında özellik seçme aşaması, veri setinden istenmeyen özelliklerin pearson korelasyon katsayısı ile çıkarılması ile başlar. Ardından, algoritma en uygun özellikleri seçer. GLEO, $(N \times D)$ boyutunda bir başlangıç çözümü ile özellik seçmeyi başlatır. N , parçacıkların sayısıdır ve D özellik sayısıdır. Her bir vektör bir özelliğe karşılık gelir. Özellik seçimi için eşik değeri olarak 0.5 belirlenmiştir (Too & Mirjalili, 2021).

$$\begin{aligned} c_i^d > 0.5, & \quad \text{seçilmiş özellik} \\ c_i^d \leq 0.5, & \quad \text{seçilmemiş özellik} \end{aligned}$$

Bu algoritmada her bir parçacığı değerlendirmek için bir uygunluk fonksiyonu kullanılır. Uygunluk fonksiyonu aşağıdaki gibidir;

$$\text{Uygunluk fonksiyonu} = \gamma CE + (1 - \gamma) \frac{|R|}{|F|} \quad (7)$$

Burada CE sınıflandırma hatası, $|R|$ azaltılmış özellik alt kümesinin uzunluğu, $|F|$ özellik sayısı ve γ kontrol parametresidir.

2.4. Salp Sürü Algoritması

SSA isminden de anlaşılacağı üzere doğada salp adı verilen canlıların hareketlerinden esinlenerek 2017 yılında Mirjalili tarafından geliştirilmiş bir metasezgisel optimizasyon algoritmasıdır. Bu canlılar okyanusun diplerinde yaşarlar ve jel kıvamında bir yapıya sahiptirler. Salpler yaşam alanlarında bir zincir halinde hareket ederler ve bu bir salp zincirine benzetilmektedir. Bu canlılar ilk defa bu algoritma ile bir optimizasyon problemlerinin çözümü için kullanılmıştır (Mirjalili vd., 2017).

Bu algoritmada matematiksel modellemeyi yapmak için ilk olarak salp zinciri iki bölüm olarak varsayılır. Bunlardan ilki lider salp ve ikincisi takipçi salplerdir. Diğer sürü tabanlı optimizasyon algoritmalarında olduğu gibi burada da bir arama uzayı vardır. Salplerin pozisyonları n boyutlu bir arama uzayını tanımlar ve n problemdeki değişkenlerin sayısıdır. Bu yüzden salplerin konumları iki boyutlu bir x matrisinde toplanır. Aynı zamanda F ile sembolize edilen, salplerin ulaşmak istediği bir besin kaynağı olduğu da varsayılır. Lider salpin konumunu güncellemek için kullanılan eşitlik aşağıdaki gibidir;

$$x_j^1 = \begin{cases} F_j + c_1 \left((ub_j - lb_j)c_2 + lb_j \right) & c_3 \geq 0 \\ F_j - c_1 \left((ub_j - lb_j)c_2 + lb_j \right) & c_3 < 0 \end{cases} \quad (8)$$

Eşitlikte x_j^1 lider salpin konumunu gösterir ve F_j , j .boyuttaki besin kaynağıdır. ub_j ve lb_j sırasıyla j .boyutun üst ve alt limitidir. Eşitlik 8 göstermektedir ki salp sürü algoritmasında lider konumunu sadece besin kaynağına göre değiştirmektedir. Burada c_2, c_3 0 ile 1 arasında seçilmiş rastgele sayılardır, c_1 parametresi ise algoritmanın keşif ve sömürü verimliliği açısından önemlidir ve aşağıdaki şekilde ifade edilir.

$$c_1 = 2e^{-(4l/L)^2} \quad (9)$$

l , o andaki iterasyon sayısını, L maksimum iterasyonu gösterir. Takipçi salplerin konumlarını güncellemek için aşağıdaki eşitlik kullanılır;

$$x_j^i = \frac{1}{2}at^2 + v_0t \quad (10)$$

Eşitlik 10'da v_0 başlangıç hızını, t zamanı, x_j^i ise j .boyuttaki i . takipçi salpin konumunu göstermektedir ve $a = \frac{v_{final}}{v_0}$, $v = \frac{x-x_0}{t}$ şeklindedir. Optimizasyonda zaman, iterasyon olduğundan, iterasyonlar arasındaki tutarsızlık 1 olarak ve $v_0=0$ olarak kabul edilir. Böylelikle eşitlik 10 aşağıdaki şekilde oluşur.

$$x_j^i = \frac{1}{2}(x_j^i + x_j^{i-1}) \quad (11)$$

Algoritma 1. SSA sözde kodu

```

ub ve ul dikkate alınarak salp popülasyonunun xi(i = 1,2, ..., n) belirlenmesi
Son koşul sağlanmadığında
Her arama ajanının (salp) uygunluğunu hesapla
F'i en iyi arama ajanı olarak ayarla
Eşitlik 19 kullanılarak c1 güncelle
Her salp (xi) için
Eğer (i ==1) sonra
Lider salpin konumunu güncelle
Değilse
Takipçi salpin konumunu güncelle
Değişkenlerin alt ve üst sınırlarına dayanarak salpleri güncelle
F'e dön

```

Diğer metasezgisel algoritmalarda olduğu gibi salp sürü algoritmasında da optimizasyon süreci rastgele üretilmiş çözüm popülasyonu ile başlar. Ardından çözüm bir amaç fonksiyonu ile değerlendirilir. Salp sürü algoritmasında en iyi çözüm F , yani besin kaynağı

olarak kabul edilir. Her iterasyonda c_1 parametresi eşitlik (9) ile güncellenir, her boyut eşitlik (8) ile ve takipçi salplerin konumları eşitlik (11) ile güncellenir. Bütün adımlar en iyi çözüm bulunana kadar tekrarlanır. Optimizasyon boyunca Aynı zamanda F 'de güncellenir (Mirjalili vd., 2017).

2.4.1. Salp sürü algoritması ile özellik seçme

Özellik seçme problemlerinde çözümler 0 ve 1'e sabitlemiştir. SSA algoritmasında da özellik seçme işleminde durum aynıdır. Bir özellik vektörü oluşturulur ve bu vektörün uzunluğu veri setindeki özellik sayısı kadardır. Vektördeki her değer 0 ya da 1'dir. Eğer vektörün bir hücresindeki değer 1 ise özellik seçilmiştir, 0 ise seçilmemiştir (Hegazy vd., 2020).

$$x_j^i = \begin{cases} 1 & \text{if } M_{ij} > 0.5 \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

x_j^i çözüm vektörünün ayırık formudur. M_{ij} ve M arama ajanı i 'nin j .boyuttaki konumudur.

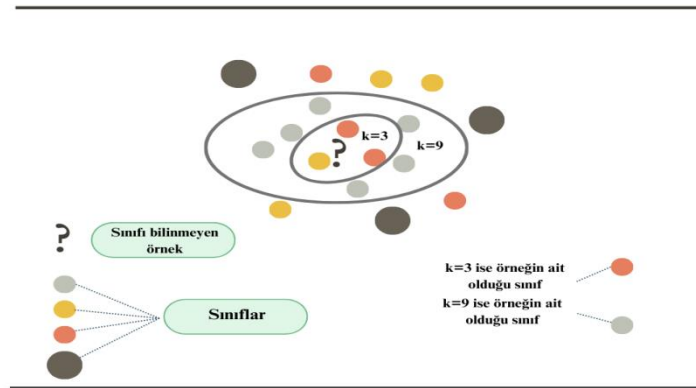
SSA, özellik seçme sürecini çok amaçlı bir optimizasyon problemi olarak modeller. Burada iki tane ulaşılmaması gereken amaç vardır; bunlar en az özellik sayısı ve maksimum sınıflandırma doğruluğudur. Her çözümdeki seçilmiş minimum özelliklerin sayısı maksimum doğruluk oranı arasındaki denge için eşitlik (13)'teki uygunluk fonksiyonu kullanılır.

$$Fitness = \rho Err(D) + \varphi \frac{|K|}{|T|} \quad (13)$$

$Err(D)$, tanımlanan alt kümenin sınıflandırıcı hata oranıdır. ρ ve φ özellik azaltma ve sınıflandırma doğruluğunu kontrol için olan sabitlerdir, $|K|$ (tanımlanan altkümedir, $|T|$) özelliklerin toplam sayısıdır. ρ 0 ile 1 arasındadır ve $\varphi = (1 - \rho)$ şeklindedir (Mirjalili vd., 2017, Hegazy vd., 2020).

2.5. K-En Yakın Komşu Algoritması

KNN, veri madenciliği, sınıflandırma, regresyon ve örüntü tanıma gibi alanlarda sıklıkla kullanılan, geleneksel ve parametrik olmayan bir algoritmadır. Algoritmada bir özellik vektörü ile temsil edilen ve hangi sınıfa ait olduğu bilinmeyen veri ya da örnek en yakın k sayıda komşusunda çoğunluk olan sınıfa ait olarak kabul edilir. Burada k sabit bir sayıdır. Şekil 4'te KNN algoritmasının sınıfı bilinmeyen bir örneği nasıl sınıflandırdığı gösterilmiştir.

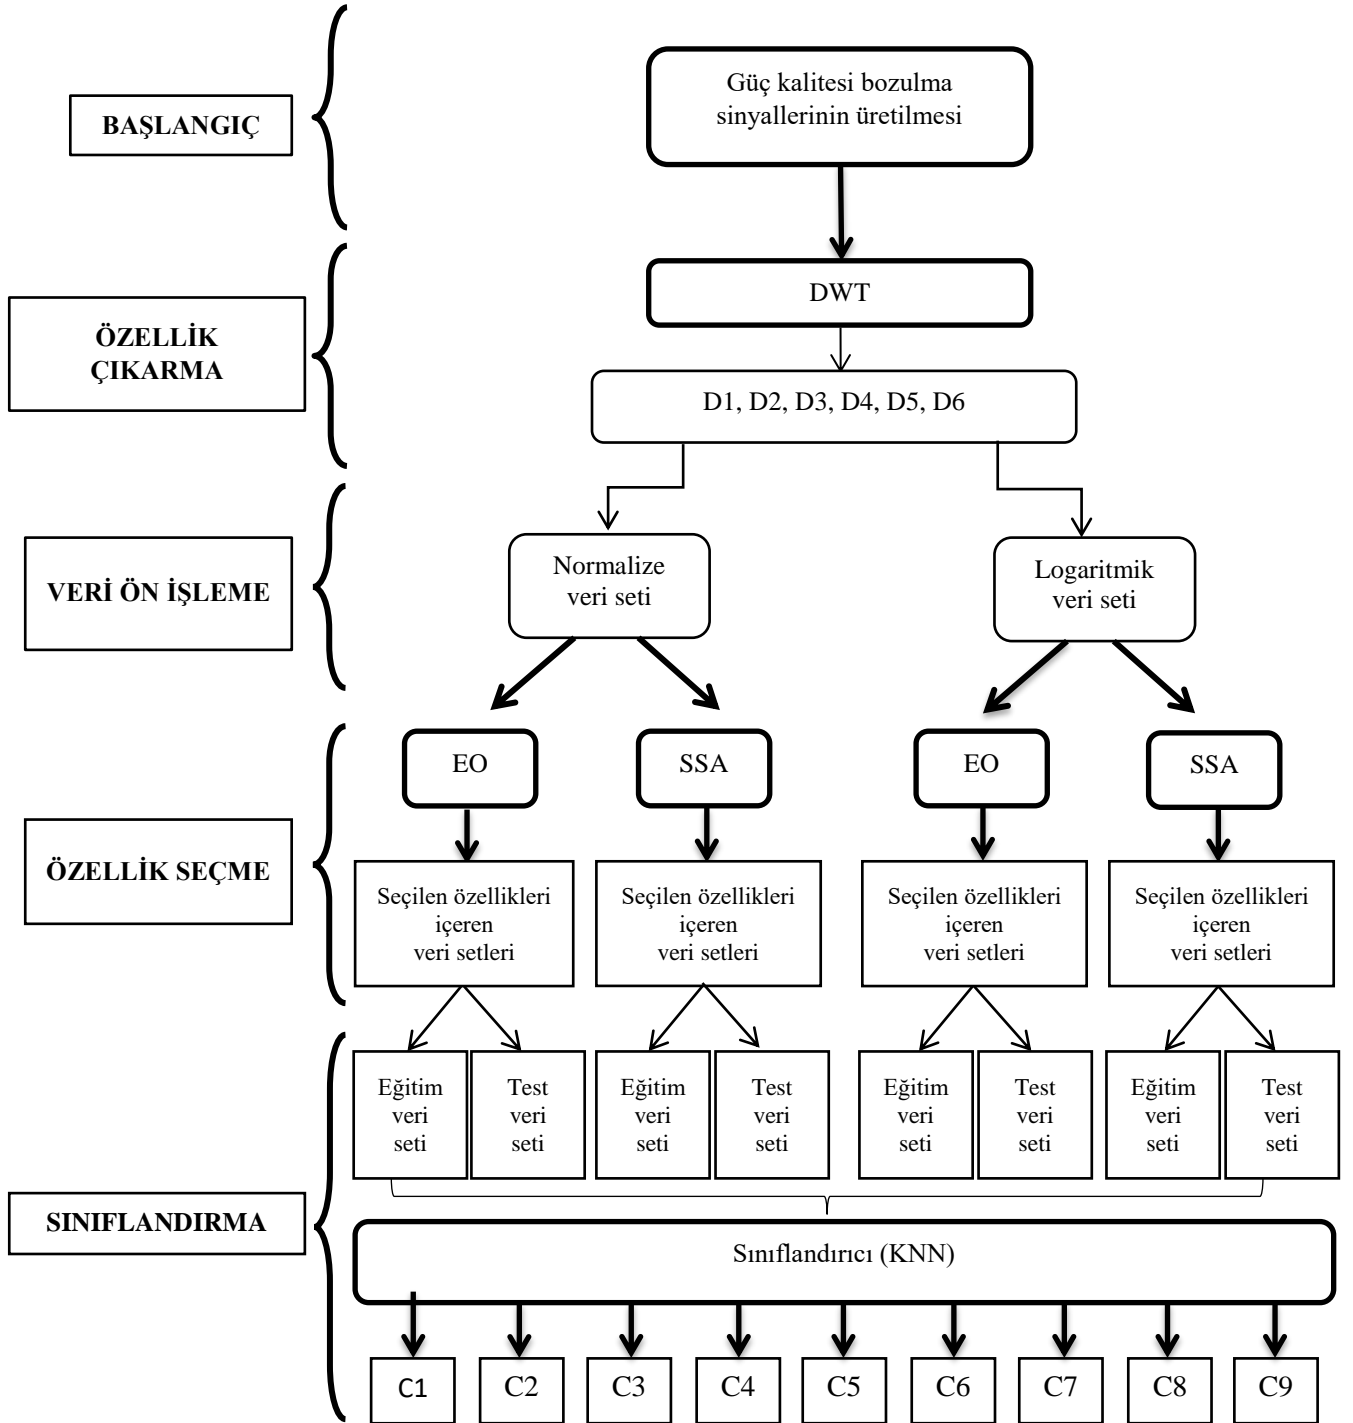


Şekil 4. KNN Algoritması (Hu vd., 2016)

KNN' de mesafe ölçümleri için farklı yöntemler kullanılabilir. Öklid, Manhattan, Chebyshev, Minkowski bunlardan bazılarıdır. Farklı ölçüm yöntemleri farklı sonuçlar oluşturabilirken, farklı veri dağılımları da farklı yöntemler gerektirebilmektedir. Öklid yöntemi en yaygın ölçüm yöntemi olarak kullanılmaktadır. KNN, basit ve anlaşılır olması sebebiyle kullanım kolaylığı sunmaktadır. Ancak algoritmada mesafe ölçümü söz konusu olduğundan büyük veri setlerinde hesaplama maliyeti yüksek olmaktadır ve performansı düşmektedir. Ayrıca "k" değerinin ne olarak belirleneceği de algoritmanın verimini etkileyen faktörlerdendir (Hu vd., 2016; Zhang vd., 2014).

3. Güç Kalitesi Olaylarının Sınıflandırma Süreci

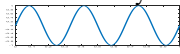
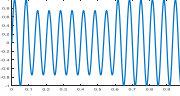
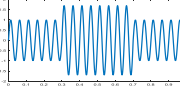
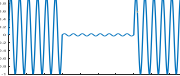
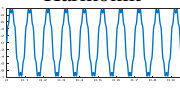
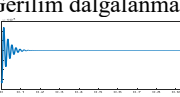
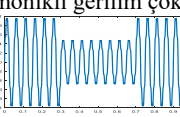
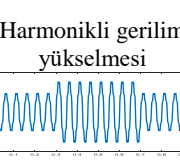
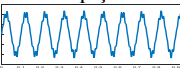
Çalışmanın bu bölümünde, sınıflandırma sürecine ait bütün aşamalar Şekil 5' teki akış diyagramında gösterildiği gibi gerçekleştirilmektedir.



Şekil 5. Çalışmanın Akış Diyagramı

Sınıflandırma süreci, Tablo 1'de parametrik denklemleri verilen güç kalitesi olayları için tamamlanmıştır (Akmaz,2022).

Tablo 1. Güç Kalitesi Olayları (Akmaz,2022)

Sınıf	Güç kalitesi olayı	Güç kalitesi olayının parametrik denklemi	Parametreler ve limitler
Sınıf 1	Saf sinüs sinyali 	$V(t)=\sin(2\omega t)$	Frekans=50Hz
Sınıf 2	Gerilim çökmesi 	$V(t)=(1-\alpha(u(t-t_1)-u(t-t_2)))\sin(\omega t)$	$0.1 \leq \alpha \leq 0.9$ $T \leq t_2 - t_1 \leq 9T$
Sınıf 3	Gerilim yükselmesi 	$V(t)=(1+\alpha(u(t-t_1)-u(t-t_2)))\sin(\omega t)$	$0.1 \leq \alpha \leq 0.8$ $T \leq t_2 - t_1 \leq 9T$
Sınıf 4	Kesinti 	$V(t)=(1-\alpha(u(t-t_1)-u(t-t_2)))\sin(\omega t)$	$0.9 \leq \alpha \leq 1$ $T \leq t_2 - t_1 \leq 9T$
Sınıf 5	Harmonik 	$V(t)=(\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t))$	$0.05 \leq \alpha_3 \leq 0.15$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $\sum \alpha_i^2 = 1$
Sınıf 6	Gerilim dalgalanması 	$V(t)=\sin(\omega t) + \alpha_{osc} \exp(-(t-t_1)/\tau_{osc}) \sin(\omega_{nosc}(t-t_1))$	$\tau_{osc}=0.008-0.04$ sn $\omega_{nosc}=100-400$ Hz
Sınıf 7	Harmonikli gerilim çökmesi 	$V(t)=(1-\alpha(u(t-t_1)-u(t-t_2)))$ $(\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t))$	$0.1 \leq \alpha \leq 0.9$ $T \leq t_2 - t_1 \leq 9T$ $0.05 \leq \alpha_3 \leq 0.15$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $\sum \alpha_i^2 = 1$
Sınıf 8	Harmonikli gerilim yükselmesi 	$V(t)=(1+\alpha(u(t-t_1)-u(t-t_2)))$ $(\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t))$	$0.1 \leq \alpha \leq 0.8$ $T \leq t_2 - t_1 \leq 9T$ $0.05 \leq \alpha_3 \leq 0.15$ $0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15$ $\sum \alpha_i^2 = 1$
Sınıf 9	Kırpışma 	$V(t)=(1+\alpha_f \sin(\beta_f \omega t))\sin(\omega t)$	$\alpha_f = 0.1-0.2$ $\beta_f = 5-10$ Hz

3.1. Güç Kalitesi Olaylarının Üretilmesi

Güç kalitesi bozukluklarını, parametrik denklemler ve kontrol parametreleriyle sentetik olarak üretmek bunlarla ilgili yapılan çalışmalarda avantaj sağlamaktadır. Laboratuvar ortamında kontrol edilebilir deneyimler sağlamaktadır. Parametreler değiştirilerek çok fazla sayıda sinyal üretilebilir ve birçok koşulu test etmek mümkün olabilir. Güç kalitesi olaylarını sınıflandırma konusunda da durum benzerdir. Frekans, genlik veya harmonik gibi parametrelerin ayarlanabilir ve kontrol edilebilir olması sınıflandırma çalışmasında standart ve karşılaştırılabilir koşullar oluşturmaya olanak sağlar. Parametrelerin farklılaştırılmasıyla çok sayıda güç kalitesi olayının üretilmesi, sınıflandırmanın çok sayıda veri noktasına ve çeşitliliğe sahip olması açısından önemlidir. Sınıflandırma algoritmalarını ve modellerini belirli bozukluk türleri için özelleştirmek ve iyileştirmek daha kolay olabilir. Gerçek dünya verilerini kullanmak maliyetli ve riskli olabilirken, sentetik sinyal üretimi çok geniş veri seti toplama imkânı sunar.

Bu çalışmada güç kalitesi olayları Matlab/2022a yazılım programında üretilmiştir. Örnekleme frekansı 12.8 KHz olarak tercih edilmiştir. Her bir güç kalitesi olayı Tablo 1'deki parametrik denklemler kullanılarak kontrol parametreleri ile üretilmişlerdir. Her bir sinyalden 150 farklı sinyal olmak üzere toplamda 1350 adet sentetik sinyal üretilmiştir.

3.2. Özellik Çıkarma

Özellik çıkarma süreci güç kalitesi olaylarının sınıflandırılmasında önemli bir rol oynamaktadır. Bu çalışmada, özellik çıkarma için DWT yöntemi kullanılmıştır. Her bir güç kalitesi olayı için elde edilen 150 farklı sinyal, DWT yöntemi ile 6 seviye için ve 5 farklı ana dalgacık kullanılarak ayrıştırılmıştır. Daubechies4 (db4), Daubechies2 (db2), Symlet4 (sym4), Biorthogonal3.3 (bior3.3), Coiflet (coif3) kullanılan ana dalgacıklardır. Enerji formülü ile sinyaller üzerinde özellik çıkarımı yapılmıştır. Sinyallerin enerji değerleri aşağıdaki formül ile hesaplanmaktadır;

$$E_{ki} = \sum_{j=1}^N |C_{ij}|^2 \quad (14)$$

Özellik çıkarma işleminin sonucunda her bir güç kalitesi olayı için 150*30 boyutlu veri setleri elde edilmiştir ve bu veri setleri birleştirilerek toplamda 1350*30 boyutlu özellik matrisi oluşturulmuştur.

3.3. Özellik Seçme ve Sınıflandırma

Özellik seçme aşaması, sınıflandırma çalışmalarının verimli ve başarılı sonuçlanması açısından kritik bir adımdır. Veri setindeki alakasız özelliklerin kaldırılması ve en gerekli olanların seçilmesi sürecidir. Bu işlemle veri setindeki özellik sayısı azalacağından modelin eğitilmesi ve değerlendirilmesi için geçen süre azalır. Yüksek bellek gereksinimi ortadan kalkabilmektedir. Gürültülü ve gereksiz özelliklerin ortadan kaldırılması modelin daha iyi genelleme yapmasını sağlayabilir.

Bu çalışmada özellik seçme için metasezgisel tabanlı optimizasyon algoritması kullanılmıştır. Bunlar EO ve SSA algoritmalarıdır. Sınıflandırma için ise KNN algoritması tercih edilmiştir. KNN sınıflandırma algoritması, Matlab 2022/a Classification Learner Toolbox kullanılarak eğitilmiştir. Sarmal tabanlı özellik seçme algoritmaları özellikle bu çalışmada kullanılan KNN gibi sınıflandırma veya kümeleme algoritmalarına özgü özellik seçimini uyarlayabilir, böylece KNN' nin özel gereksinimlerine daha uygun özelliklere ulaşabilir. KNN ve benzeri yakınlık tabanlı algoritmaların performansı, özellik setinin seçimine büyük ölçüde bağlıdır. KNN gibi algoritmalar, çok sayıda gereksiz ve gürültülü özelliklerle eğitildiğinde genelleme yeteneğini kaybedebilir. Sarmal tabanlı seçim algoritmaları, ilgisiz veya gürültülü özellikleri kaldırarak bu riski azaltabilir. Özetle, sarmal tabanlı özellik seçme algoritmaları, KNN' nin belirli ihtiyaçlarına uyacak şekilde geliştirilmiş performansla, azalmış hesaplama maliyetine ve daha iyi genelleme yeteneğine sahiptir.

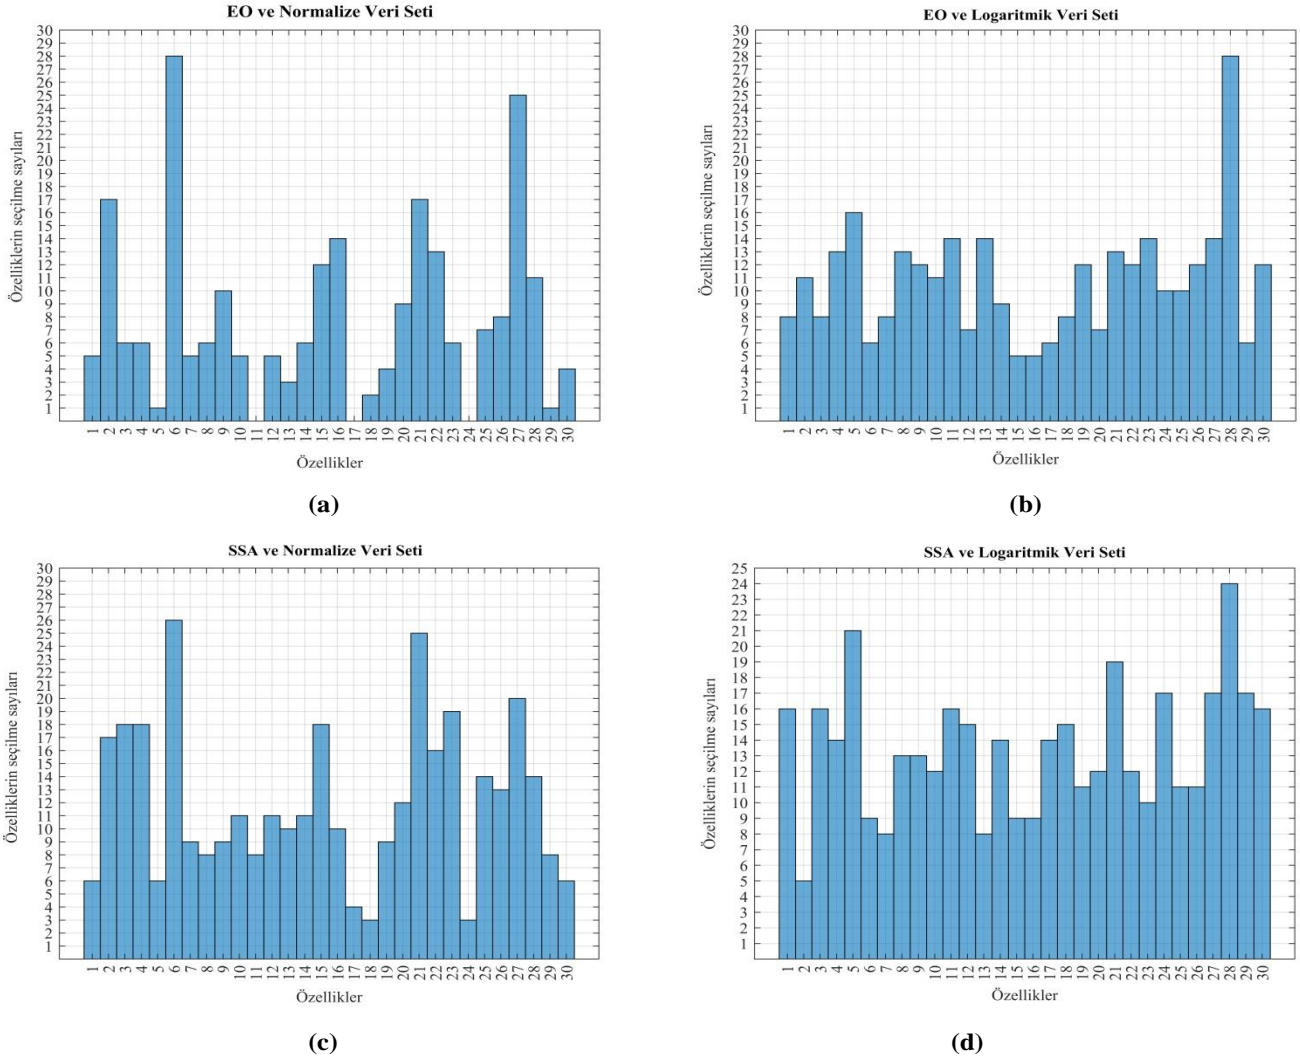
Buradaki özellik seçme işlemi algoritmaların giriş parametreleri ayarlanarak gerçekleştirilmiştir. Her iki algoritmada da maksimum iterasyon sayısı 100 olarak seçilmiştir çünkü 100 iterasyondan sonra en iyi sonucun değişmediği gözlemlenmiştir. Elde edilen veri seti ilk olarak normalize edilerek ve logaritması alınarak iki farklı veri seti haline getirilmiştir. Bu iki farklı veri seti ile her iki algoritmaya da 30 kez özellik seçme işlemi yaptırılmış ve hepsi için KNN ile sınıflandırma tamamlanmıştır. Elde edilen her bir 30 doğruluk oranı not edilmiştir ve doğruluk oranlarının en yüksek değeri, en düşük değeri, ortalama değeri ve standart sapma değeri hesaplanmıştır. Hesaplamaların sonuçları Tablo 2'de verilmiştir. Tablo 2 göstermektedir ki en yüksek sınıflandırma doğruluk oranı, özellik seçme algoritmasının EO olduğu ve logaritmik veri setinin kullanıldığı durumda elde edilmiştir. En düşük sınıflandırma doğruluk oranı ise özellik seçme algoritması olarak SSA'nın, veri seti olarak da normalize veri setinin kullanıldığı durumda ortaya çıkmıştır.

Tablo 2. Sınıflandırma Doğruluk Oranları

	EO		SSA	
	Normalize veri seti	Logaritmik veri seti	Normalize veri seti	Logaritmik veri seti
Ortalama	% 93.33	% 94.65	% 92.19	% 94.44
Standart sapma	0.94	1.06	1.01	0.63
En yüksek değer	% 94.81	% 96.05	% 94.07	% 95.56
En düşük değer	% 90.86	% 91.06	% 90.62	% 93.09

4. Histogram Grafiği Sonucunda Elde Edilen Sınıflandırma Sonuçları

Çalışmanın bu bölümünde seçilen özellikleri en çok seçilenden ez az seçilene doğru sıralayarak, belli sayıda en çok seçilen özelliklerle yeniden sınıflandırma yapmak ve doğruluk oranını yükseltmek hedeflenmiştir. Bunun için, özellik seçme aşamasında her iki algoritmanın her iki veri seti ile 30 kez çalıştırılmasından seçilen özelliklerin histogram grafikleri çıkarılmıştır. Böylece bir özelliğin kaç kez seçildiği tespit edilmiştir. Çıkarılan histogram grafikleri Şekil 6'te gösterilmiştir.



Şekil 6. Histogram Grafikleri

Histogram grafiklerinden elde edilen verilere bakarak, her bir grafikteki en çok seçilen 8 özellik belirlenmiştir.

Şekil 6(a)'da verilen histogram grafiğine göre en çok seçilen 8 özellik 6, 27, 2, 21, 16, 22, 28, 9 şeklinde sıralanmıştır. Şekil 6(b)'de verilen histogram grafiğine göre en çok seçilen 8 özellik 28, 5, 13, 27, 4, 8, 30, 19 şeklinde sıralanmıştır. Şekil 6(c)'de verilen histogram grafiğine göre en çok seçilen 8 özellik 6, 21, 27, 23, 15, 4, 2, 22 ve Şekil 6(d)'de verilen histogram grafiğine göre en çok seçilen 8 özellik ise 28, 5, 21, 27, 24, 30, 11, 12 şeklinde sıralanmıştır.

Seçilmiş bu özellikler ile yine KNN kullanılarak sınıflandırma yeniden yapılmıştır. Birinci kısımda elde edilen ortalama sınıflandırma doğruluk oranları ile histogram grafikleri kullanılarak yapılan sınıflandırmaların doğruluk oranları Tablo 3'te verilmiştir.

Tablo 3. Sınıflandırma Doğruluk Oranlarının Karşılaştırılması

Özellik seçme algoritması	Veri seti	KNN Sınıflandırma doğruluk oranları (%)	
EO	Normalize veri seti	30 çalışma ortalaması	93.33
		En çok seçilen 8 özellik ile	94.57
	Logaritmik veri seti	30 çalışma ortalaması	94.65
		En çok seçilen 8 özellik ile	95.8
SSA	Normalize veri seti	30 çalışma ortalaması	92.19
		En çok seçilen 8 özellik ile	93.83
	Logaritmik veri seti	30 çalışma ortalaması	94.44
		En çok seçilen 8 özellik ile	95.06

5. Sonuç ve Gelecek Çalışmalar

Bu çalışmada güç kalitesi olaylarının sınıflandırılmasında, özellik seçme için metasezgisel tabanlı özellik seçme algoritmalarının kullanılmasının, sınıflandırma başarısına etkisi incelenmek istenmiştir. Bunun için EO ve SSA algoritması özellik seçme için kullanılmıştır. Kullanılan algoritmalar özellik seçme yaklaşımlarının, sarmal tabanlı olanlar kategorisinde yer aldığından, sınıflandırma yöntemi olarak da bu yaklaşıma uygun bir yöntemin tercih edilmesinin başarıyı artıracacağı düşünülmüştür. Sarmal tabanlı özellik seçme yaklaşımıyla uyumlu ve verimli çalışmasından dolayı sınıflandırıcı olarak KNN tercih edilmiştir.

Üretilen güç kalitesi olaylarının DWT ile ayrıştırılmış ve özellikleri çıkarılmıştır. Özellik seçme algoritmaları veri setleri kullanılarak 30 kez çalıştırılmıştır. Seçilen özelliklerle KNN kullanılarak sınıflandırma işlemi yapılmıştır. Çalışmanın ikinci kısmında, histogram grafiklerinden elde edilen özellikler kullanılarak yeniden sınıflandırma işlemi yapılmış olup, elde edilen doğruluk oranlarının daha yüksek olduğu gözlenmiştir.

Mevcut çalışma, aşağıdaki yöntemleri içerecek şekilde genişletilebilir:

- Önerilen modelin gerçek zamanlı veriler ile test edilmesi
- Veri seti miktarı artırılarak doğruluk oranlarının analiz edilmesi
- Derin öğrenme metotları ile gürültü içeren güç kalitesi olaylarının sınıflandırılması.

Referanslar

Abdoos, A. A., Mianaei, P. K., & Ghadikolaei, M. R. (2016). Combined VMD-SVM based feature selection method for classification of power quality events. *Applied Soft Computing*, 38, 637–646.

Afroni, M. J., Sutanto, D., & Stirling, D. (2013). Analysis of nonstationary power-quality waveforms using iterative Hilbert Huang transform and SAX algorithm. *IEEE Transactions on Power Delivery*, 28(10), 2134–2144.

Akmaz, D. (2022). Recognition of Power Quality Events Using Wavelet Transform, K-Nearest Neighbor Algorithm, and Gain Ratio Feature Selection Method. *International Journal of Innovative Engineering Applications*, 6(1).

Balouji, E., Gu, I.Y.H., Bollen, M.H.J., Bagheri, A., & Nazari, M. (2018). A LSTM-based deep learning method with application to voltage dip classification. In: 2018 18th International Conference on Harmonics and Quality of Power (ICHQP), Ljubljana, pp. 1–5.

Bih, J. (2006). Paradigm shift - an introduction to fuzzy logic. *IEEE Potentials*, 25(1), 6–21.

Biswal, T., & Parida, S.K. (2022). A novel high impedance fault detection in the micro-grid system by the summation of accumulated difference of residual voltage method and fault event classification using discrete wavelet transforms and a decision tree approach. *Electric Power Systems Research*, 209, 108042.

Coban, M., Sungur, S. T., & Tezcan, T. (2021). Detection and classification of short-circuit faults on a transmission line using current signal. *Power Systems and Power Electronics, Bulletin of the Polish Academy of Sciences, Technical Sciences*, 69(4), e137630. DOI: 10.24425/bpasts.2021.137630

- Darrow, K., Hedman, B., Bourgeois, T. & Rosenblum, D.,(2005). The Role of Distributed Generation in Power Quality and Reliability
- Dash, P. K., Panigrahi, B. K., & Panda, G. (2003). Power quality analysis using S-transform. *IEEE Transactions on Power Delivery*, 18(2), 406–411.
- Edomah, N. (2010). Economic Implications of Poor Power Quality. *Journal of Energy and Power Engineering*, 4(1), 26. ISSN 1934-8975.
- Erişti, H., Yıldırım, Ö., Eristi, B., & Demir, Y. (2013). Optimal feature selection for classification of power quality events using wavelet transform and least squares support vector machines. *Electrical Power and Energy Systems*, 49, 95–103.
- Faramarzi, A., Heidarinejad, M., Stephens, B., & Mirjalili, S. (2020). Equilibrium optimizer: A novel optimization algorithm. *Knowledge-Based Systems*, 191, 105190.
- Fikri, M., & El-Sayed, M. A. H. (1988). New algorithm for distance protection of high voltage transmission lines. *IEE Proceedings C Generation Transmission Distribution*, 135-C(5), 436–440.
- He, S., Li, K., & Zhang, M. (2013). A real-time power quality disturbances classification using hybrid method based on S-Transform and dynamics. *IEEE Transactions on Instrumentation and Measurement*, 62(9), 2465–2475.
- Hegazy, A. E., Makhlof, M. A., & El-Tawel, Gh. S. (2020). Improved salp swarm algorithm for feature selection. *Journal of King Saud University – Computer and Information Sciences*, 32, 335–344.
- Hu, L.-Y., Huang, M.-W., Ke, S.-W., & Tsai, C.-F. (2016). The distance function effect on k-nearest neighbor classification for medical datasets. *Springerplus*, 5(1), 1304.
- Kapoor, R., Kumar, R., & Tripathi, M. M. (2018). Volterra bound interval type-2 fuzzy logic-based approach for multiple power quality events analysis. *IET Electrical Systems in Transportation*, 8(3), 188–196.
- Karimi, M., Mokhtari, H., & Iravani, M. R. (2000). Wavelet based on-line disturbance detection for power quality applications. *IEEE Transactions on Power Delivery*, 15(4), 1212–1220.
- Khetarpal, P., & Tripathi, M. M. (2020). A critical and comprehensive review on power quality disturbance detection and classification. *Sustainable Computing: Informatics and Systems*, 28, 100417
- Khokhar, S., Mohd Zin, A. A., Memon, A. P., & Mokhtar, A. S. (2017). A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network. *Measurement*, 95, 246–259.
- Lee, I. W. C., & Dash, P. K. (2003). S-transform-based intelligent system for classification of power quality disturbance signals. *IEEE Transactions on Industrial Electronics*, 50(8), 800–805.
- Mafarja, M., & Mirjalili, S. (2018). Whale optimization approaches for wrapper feature selection. *Applied Soft Computing*, 62, 441–453.
- Mallat, S. G. (1989). A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1(7).
- Mirjalili, S., Gandomi, A. H., Mirjalili, S. Z., Saremi, S., Faris, H., & Mirjalili, S. M. (2017). Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems. *Advances in Engineering Software*, 114, 163–191.
- Moravej, Z., Abdoos, A. A., & Pazoki, M. (2009). Detection and classification of power quality disturbances using wavelet transform and support vector machines. *Electric Power Components and Systems*, 38(2), 182–196.
- Nashad, N. R., Islam, M. J., Alam, S., Rahat, R. M., Begum, M. T. A., & Alam, M. R. (2017). A Simplistic Mathematical Approach for Detection and Classification of Power Quality Events. *International Conference on Electrical, Computer and Communication Engineering (ECCE)*, 16-18 Şubat 2017, Cox's Bazar, Bangladesh.
- Salat, R., & Osowski, S. (2004). Accurate fault location in the power transmission line using support vector machine approach. *IEEE Transactions on Power Systems*, 19(2), 979–986.

Saunders, C., Grobelnik, M., Gunn, S., & Shawe-Taylor, J. (Eds.). (2005). Subspace, Latent Structure and Feature Selection: Statistical and Optimization Perspectives - Workshop, SLSFS 2005, Bohinj, Slovenia, February 23-25, 2005, Revised Selected Papers.

Sharma, A., Rajpurohit, B. S., & Singh, S. N. (2018). A review on economics of power quality: Impact, assessment and mitigation. *Renewable and Sustainable Energy Reviews*, 88, 363–372.

Too, J., & Mirjalili, S. (2021). General Learning Equilibrium Optimizer: A New Feature Selection Method for Biological Data Classification. *Applied Artificial Intelligence*, 35(3), 247–263.

Tse, N. C. F., Chan, J. Y. C., Lau, W., & Lai, L. L. (2012). Hybrid wavelet and Hilbert transform with frequency-shifting decomposition for power quality analysis. *IEEE Transactions on Instrumentation and Measurement*, 61(12), 3225–3233.

Upadhyay, M., Singh, A. K., Thakur, P., Nagata, E. A., & Ferreira, D. D. (2022). Mother wavelet selection method for voltage sag characterization and detection. *Electric Power Systems Research*, 211, 108246.

Uyar, M. (2008). Güç Kalitesi Bozulma Türlerinin Akıllı Örüntü Tanıma Yaklaşımları ile Belirlenmesi (Doktora tezi). Fırat Üniversitesi, Fen Bilimleri Enstitüsü.

Valtierra-Rodriguez, M., Romero-Troncoso, R. de J., Osornio-Rios, R. A., & Garcia-Perez, A. (2014). Detection and classification of single and combined power quality disturbances using neural networks. *IEEE Transactions on Industrial Electronics*, 61(5), 2473–2482.

Valtierra-Rodriguez, M., Romero-Troncoso, R. de J., Osornio-Rios, R. A., & Garcia-Perez, A. (2014). Detection and Classification of Single and Combined Power Quality Disturbances Using Neural Networks. *IEEE Transactions on Industrial Electronics*, 61(5), 2473–2482.

Zhang, S., Zong, M., Sun, K., Liu, Y., & Cheng, D. (2014). Efficient kNN Algorithm Based on Graph Sparse Reconstruction. In *International Conference on Advanced Data Mining and Applications (ADMA 2014)* (ss. 356–369).