

**T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DALGACIK TEORİSİ KULLANARAK GÜÇ
KALİTESİ VE GEÇİCİ DURUMLARIN ANALİZİ**

YÜKSEK LİSANS TEZİ

Özgür TOMAK

Enstitü Anabilim Dalı : Enerji Sistemleri Mühendisliği

Tez Danışmanı : Yrd. Doç. Dr. Onur Özdal MENGİ

Mart 2018

T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DALGACIK TEORİSİ KULLANARAK GÜÇ
KALİTESİ VE GEÇİCİ DURUMLARIN ANALİZİ**

YÜKSEK LİSANS TEZİ

Özgür TOMAK

Enstitü Anabilim Dalı : Enerji Sistemleri Mühendisliği

Bu tez 06/03/2018 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

**Yrd. Doç. Dr.
Oğuzhan ÇAKIR**

Jüri Başkanı

**Doç. Dr.
Hakan ADATEPE**

Üye

**Yrd. Doç. Dr.
Onur Özdal MENGİ**

Üye

**Doç. Dr.
Bahadır KOZ**

Enstitü Müdürü

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Özgür TOMAK

06/03/2018

TEŐEKKÜR

Tez alıőmamın tım aőamalarında her turlu bilimsel desteęi saęlayan deęerli danıőman hocam Yrd. Doę. Dr. Onur Özdal MENĐİ'ye desteęinden dolayı teőekkür ve őükranlarımı sunarım. Ayrıca hayatımın her anında yanımda olan aileme saygı ve sevgilerimi sunarım.



İÇİNDEKİLER

TEŞEKKÜR.....	III
İÇİNDEKİLER	IV
SİMGELER VE KISALTMALAR LİSTESİ	VII
ŞEKİLLER LİSTESİ	VIII
TABLolar LİSTESİ.....	IX
ÖZET	XII
SUMMARY	XIII
BÖLÜM 1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Amaç	2
1.3. Bu Konuda Yapılmış Çalışmalar	2
BÖLÜM 2. GÜÇ KALİTESİNDE BOZUKLUKLAR.....	12
2.1. Harmonikler	13
2.2. Gerilim Çökmesi	16
2.3. Gerilim Yükselmesi	17
2.4. Gerilim Kesintisi	18
2.5. Gerilim Dalgalanmaları.....	19
2.6. Gerilim Titremesi.....	20
BÖLÜM 3. DALGACIK TEORİSİ	21
3.1. Ayrık Dalgacık Dönüşümü	21
3.2. Haar Dalgacık Fonksiyonu.....	23
3.3. Daubechies Dalgacık Fonksiyonu.....	23

3.4. Meyer Dalgacık Fonksiyonu	24
3.5. Dalgacık Yöntemi Kullanılarak Gürültü Giderme	25
3.6. Dalgacık Yöntemi Kullanılarak Sıkıştırma	26
BÖLÜM 4. SINIFLANDIRMA	28
4.1. Basit Karar Ağacı	29
4.2. Orta Seviye Karar Ağacı	31
4.3. Kompleks Karar Ağacı	33
4.4. Doğrusal Ayırıcı	34
4.5. Hassas K En Yakın Komşu Sınıflandırması	35
4.6. Orta Derece K En Yakın Komşu Sınıflandırması	37
4.7. Yüzeysel K En Yakın Komşu Sınıflandırması	38
4.8. Kosinüs K En Yakın Komşu Sınıflandırması	39
4.9. Kübik K En Yakın Komşu Sınıflandırması	40
4.10. Ağırlıklı K En Yakın Komşu Sınıflandırması	41
4.11. Geliştirilmiş Ağaç	42
4.12. Torbalama Karar Ağaçları	43
4.13. Altuzay Ayırımı	44
4.14. Altuzay K En Yakın Komşu Sınıflandırması	44
4.15. RUS Geliştirilmiş Ağaç	45
4.16. Doğrusal Destek Vektör Makinesi	46
4.17. Kuadratik Destek Vektör Makinesi	47
4.18. Kübik Destek Vektör Makinesi	48
4.19. Hassas Gauss Destek Vektör Makinesi	48
4.20. Orta Derece Gauss Destek Vektör Makinesi	49
4.21. Yüzeysel Gauss Destek Vektör Makinesi	50
BÖLÜM 5. SİSTEM MODELLEMESİ	51

BÖLÜM 6. SONUÇLAR..... 56

KAYNAKLAR 67

ÖZGEÇMİŞ 74



SİMGELER VE KISALTMALAR LİSTESİ

$\Psi(t)$:Dalgacık fonksiyonu
$\Phi(t)$:Dikey dalgacık taban fonksiyonu
c_k	:Dalgacık katsayıları
ANN	:Yapay Sinir Ağları (Artificial Neural Network)
CCA	:Kanonik Korelasyon Analizi (Canonical Correlation Analysis)
CWT	:Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
DWT	:Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)
EEMD	:Ampirik Mod Ayrıştırma (Ensemble Empirical Mode Decomposition)
ELM	:Aşırı Öğrenme Makineleri (Extreme Learning Machines)
KNN	:K En Yakın Komşu (K Nearest Neighbor)
MANN	:Modüler Yapay Sinir Ağı (Modular artificial Neural Network)
MPNN	:Modüler Olasılıksal Sinir Ağı (Modular Probabilistic Neural Network)
PCA	:Temel bileşenler analizi (Principal Component Analysis)
RF	:Rastgele Orman (Random Forest)
RWSVM	:Dalgacık Destek Vektör Makinesi (Rank Wavelet Support Vector Machine)
SVM	:Destek Vektör Makinası (Support Vector Machine)
WPD	:Dalgacık Paketinin Bozunumu (Wavelet Packet Decomposition)
WPT	:Dalgacık Paket Dönüşümü (Wavelet Packet Transform)

ŞEKİLLER LİSTESİ

Şekil 2.1. Denklem 1 ve 2'ye ait harmonik içeren örnek sinyaller.....	14
Şekil 2.2. Gerilim çökmesi içeren örnek bir sinyal.....	17
Şekil 2.3. Gerilim yükselmesi içeren örnek bir sinyal.....	18
Şekil 2.4. Gerilim kesintisi içeren örnek bir sinyal.....	19
Şekil 2.5. Gerilim dalgalanması içeren örnek bir sinyal.....	19
Şekil 2.6. Gerilim titremesi (Fliker) içeren örnek bir sinyal.....	20
Şekil 3.1. İkili (dyadic) ayrıştırma ağacı [50].....	22
Şekil 3.2. Haar Dalgacık Fonksiyonu.....	23
Şekil 3.3. Daubechies Dalgacık Fonksiyonu.....	24
Şekil 3.4. Meyer Dalgacık Fonksiyonu.....	25
Şekil 3.5. Dalgacık Yöntemi Kullanılarak Gürültü Giderme.....	26
Şekil 3.6. Dalgacık yöntemi kullanılarak sıkıştırma.....	27
Şekil 4.1. Örnek bir karar ağacı.....	30
Şekil 4.2. Karar ağacı sınıflandırma aşaması.....	32
Şekil 4.3. MATLAB kullanılarak hazırlanmış bir karar ağacı.....	33
Şekil 4.4. MATLAB kullanılarak hazırlanmış doğrusal ayırıcı sınıflandırması.....	34
Şekil 4.5. MATLAB kullanılarak hazırlanmış 1 en yakın komşu sınıflandırması.....	35
Şekil 4.6. MATLAB kullanılarak hazırlanmış 10 en yakın komşu sınıflandırması.....	37
Şekil 4.7. K En Yakın Komşu Sınıflandırmasına ait bir örnek.....	39
Şekil 4.8. İki nokta arasında d mesafesi ve θ açısının görsel gösterimi.....	40
Şekil 5.1. Bozulma işaretlerini içeren sinyalin 8. Seviye Haar dalgacık dönüşümü..	52
Şekil 5.2. Bozulma işaretlerini içeren sinyalin 8. Seviye Haar dalgacık dönüşümü..	52
Şekil 5.3. Bozulma işaretlerini içeren bir sinyal, onun tekrar oluşturulmuş hali.....	53
Şekil 5.4. Sınıflandırma sürecine ait bir blok diyagram yapısı.....	55

TABLolar LİSTESİ

Tablo 2.1. Güç sistemleri için elektromanyetik olay kategorileri ve özellikleri [41].	12
Tablo 4.1. Basit Karar Ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.....	31
Tablo 4.2. Orta Seviye Karar Ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	32
Tablo 4.3. Kompleks karar ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	33
Tablo 4.4. Doğrusal ayırıcı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.....	34
Tablo 4.5. Hassas K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.....	36
Tablo 4.6. Orta Derece K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	37
Tablo 4.7. Yüzeysel K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.....	38
Tablo 4.8. Kosinüs K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.....	39
Tablo 4.9. Kübik K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.....	40
Tablo 4.10. Ağırlıklı K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	41
Tablo 4.11. Geliştirilmiş Ağaç Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	42
Tablo 4.12. Torbalama Karar Ağaçları Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	43

Tablo 4.13. Altuzay Ayırımı Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	44
Tablo 4.14. Altuzay K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	45
Tablo 4.15. RUS Geliştirilmiş Ağaç Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	45
Tablo 4.16. Doğrusal Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	46
Tablo 4.17. Kuadratik Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	47
Tablo 4.18. Kübik Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	48
Tablo 4.19. Hassas Gauss Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	49
Tablo 4.20. Orta Derece Gauss Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	49
Tablo 4.21. Yüzeysel Gauss Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.	50
Tablo 5.1. Veri tabanında belirlenen dokuz farklı sınıf.	52
Tablo 6.1. Haar dalgacığı kullanılarak yapılan sınıflandırmanın performans sonuçları.	60
Tablo 6.2. Meyer dalgacığı kullanılarak yapılan sınıflandırmanın performans sonuçları.	61
Tablo 6.3. db2 dalgacığı kullanılarak yapılan sınıflandırmanın performans sonuçları.	62
Tablo 6.4. db4 dalgacığı kullanılarak yapılan sınıflandırmanın performans sonuçları.	63
Tablo 6.5. db6 dalgacığı kullanılarak yapılan sınıflandırmanın performans sonuçları.	64

Tablo 6.6. Sınıflandırma Yöntemine göre En Yüksek Başarı gösteren dalgacıklar. . 65
Tablo 6.7. Değişik Dalgacık türlerine ait ortalama performans değerleri..... 66



DALGACIK TEORİSİ KULLANARAK GÜÇ KALİTESİ VE GEÇİCİ DURUMLARIN ANALİZİ

ÖZET

Elektrik, modern toplumun temel ihtiyaçlarından biridir. Elde edilmesi kolaydır. Elektronik cihazların sayısındaki ve kullanımındaki artış elektrik enerjisine ihtiyacı artırmaktadır. Yüksek kalitede elektrik ihtiyacı, yeterli bakımı yapılmış elektrik şebekeleri ile mümkündür. Elektrik şebekesi, ihtiyacı olan kullanıcılara elektrik enerjisi iletmek üzere oluşturulan bir ağ için elektrik üretir. Elektrik şebekesi temel olarak, generatör, iletim ve dağıtım hatları, aradaki transformatörlerden ve yüklerden oluşur. Üretim noktalarında yüksek gerilimlere çıkarılan elektrik daha sonra dağıtım noktalarında daha alçak gerilimlere indirilir ve dağıtılır. Üretim ve dağıtım yapan kuruluşların bu süreçte kaliteli, ucuz ve kesintisiz enerjiyi kullanıcılarına ulaştırması gerekmektedir.

Güç kalitesi elektronik cihazların ömrünü uzatma ve arızaların önüne geçme açısından önemli bir unsurdur. Pahalı elektronik cihazların güç kalitesinden dolayı bozulması tüketiciler ile dağıtım yapan kuruluşlar arasında sorunlar çıkmasına neden olmaktadır. Bu tez, güç kalitesindeki bozulmayı belirlemeyi amaçlamaktadır. Bozulmaların tespit edilmesi önlem alma imkânı sağlamaktadır. Bu amaçla, oluşturulacak sistem, özellik çıkarımı için Dalgacık Dönüşümünü kullanır. Güç kalitesi bozulmalarına ait dokuz sınıf belirlenmiştir. Özellik sayısını azaltmak ve sınıflandırmayı hızlandırmak için temel bileşen analizi kullanılmıştır. 21 adet sınıflandırma yönteminin performansları incelenerek en uygun sınıflandırma yöntemi seçilmiştir. Tablolardaki sonuçlar MATLAB programı kullanılarak elde edilmiştir.

Anahtar Kelimeler : Güç Kalitesi, Dalgacık Analizi, Temel Bileşen Analizi, Sınıflandırma.

ANALYSIS OF POWER QUALITY AND TEMPORARY STATUS USING THEORY OF WAVELET

SUMMARY

Electricity is one of the essential needs of modern society. It is easy to obtain. The increase in the number and the usage of electronic devices increase the need for electricity. The requirement of high-quality electricity is possible with adequately maintained electricity networks. The electric network generates electricity for a grid that is created to transmit electrical energy to users who need it. Electric network mainly consists of generator, transmission and distribution lines, in-between transformers and loads. The electricity, which is extracted at high voltages at the production points, is then lowered and distributed at lower voltages at the distribution points. Production and distribution organizations need to deliver high quality, cheap and uninterrupted energy to their users.

Power quality is an essential factor in extending the life of electronic devices and preventing failures. Disruption of expensive electronic devices due to power quality causes problems between consumers and distributing organizations. This thesis aims to determine the deterioration of the quality of the power. Detection of deterioration provides the opportunity to take precautions. For this purpose, the system to be created uses Wavelet Transformation for feature extraction. Nine classes of power quality deterioration have been identified. Principal component analysis was used to reduce the number of features and accelerate classification. The performances of 21 classification methods were examined, and the most appropriate classification method was chosen. The results in the tables were obtained using the MATLAB program.

Key Words: Power Quality, Wavelet Analysis, Principal Component Analysis, Classification.

BÖLÜM 1. GENEL BİLGİLER

Güç sistemi, üretim, iletim ve dağıtım olmak üzere üç temel bileşene ayrılabilen karmaşık, birbirine bağlı bir ağıdır. Güneş panelleri ve rüzgâr türbinleri gibi çevreci seçenekler dışında nükleer ya da fosil yakıtlardan elde edilmesi mümkündür. Üretilen elektrik enerjisini müşterilere aktarmak için, birbirine bağlı bir iletim sistemi gereklidir. İletim sistemi, normal şartlar altında komşu bölgeleri birbirine bağlayan iletim hatlarından oluşur. Dağıtım sistemi, trafo merkezlerinin, havayolu veya yer altı kablosuyla bağlandığı, müşterinin donanımına güç aktardığı bir bölümdür. Yük olarak çok sayıda aydınlatma, ısıtma ve soğutma gibi cihazlardan oluşan bir sistemden bahsetmekteyiz.

1.1. Giriş

Kaliteli gerilim olarak sabit genlikli ve sabit frekansta sinüs şeklinde bir gerilimden bahsedilmektedir. Bu Türkiyede 220 Volt ve 50 Hz olarak karşımıza çıkar. Kullanıcıların cihazlarını etkileyen, güç sinyalinin gerilim, akım veya frekansındaki herhangi bir bozulma, bir güç kalitesi sorunu olarak adlandırılabilir. Hassas yarı iletken cihazların hemen hemen her türlü endüstriyel makina ve tüketici elektroniğine yayılması, güç kalitesindeki problemlerin azaltılmasını önemli hale getirmiştir.

Bu bozukluklar çok kısa sürmesine rağmen endüstriyel uygulamalarda büyük kayıplara ve saatlerce üretim kesintilerine neden olabilir. Bu nedenle, güç kalitesi bozulmalarının sınıflandırılmasına ve ilgili cihaz hassasiyeti çalışmalarına yönelik çalışmalara ihtiyaç duyulmaktadır.

1.2. Amaç

Güç kalitesi artan elektronik cihaz sayısına bağlı olarak gittikçe daha önemli bir konu haline almaktadır. Bundan dolayı elektrik üretimi ve dağıtımını yapan şirketler güç kalitesi bozuklarını en aza indirgeyecek yöntemler geliştirmek zorunda kalmışlardır.

Bu tezdeki amaç güç kalitesindeki bozulmaları tespit eden bir sistem oluşturması için kullanılabilir bir yöntem geliştirmektir. Başka bir deyişle elektrik üretim ve dağıtım yapan şirketlere doğru ve hızlı danışmanlık yapan bir yapay zekâ yardımı sunmaktır. Ayrık dalgacık dönüşümü (Discrete Wavelet Transform, DWT) kullanarak elde edilen özellikler kullanılarak güç kalitesine ait bozulmaların tespit edilmesi hedeflenmiştir. Bozulmaları tespit ederken 8 bozuk sinyal çeşidi ve bunlara ilave 1 normal sinyal olmak üzere 9 sınıf belirlenmiştir. Oluşturulan bu güç kalitesi bozulma işaretlerini içeren 900 tane 1,2 saniyelik sinyal oluşturulmuştur. Temel bileşenler analizi (Principal Component Analysis, PCA) kullanılarak özellik sayısı azaltılmış ve böylece sınıflandırma aşaması daha hızlanmıştır. Değişik sınıflandırma yöntemleri incelenerek en uygun yöntem belirlenmiştir.

1.3. Bu Konuda Yapılmış Çalışmalar

Poisson ve ark. [1] gerilim düşüşlerini tespit etmek için sürekli dalgacık dönüşümlerinin kullanıldığı bir yöntem önerdi. Analiz edilen sinyaller, bir zaman frekans düzlemi üzerinde ölçüldü ve standart kıyaslama değerleri ile karşılaştırıldı. Herhangi bir aksilik sinyalde bir bozulma olduğunu göstermekteydi. Bu algoritma, doğru zaman lokalizasyonu, gerilim düşüşlerinin büyüklüğünün ölçülmesi ve geçici tanımlamayı mümkün kıldı.

Poisson ve ark. [2] bozulmaların saptanması için sürekli dalgacık dönüşümü (Continuous Wavelet Transform, CWT), çoklu çözünürlük analizi ve kuadratik dönüşüm kullanımını inceledikleri çalışmalarında, analizlerin çok çözünürlüklü analiz ve kuadratik dönüşümlerin sinyallerdeki ve frekans geçişlerinde keskin değişikliklerin tespiti için yeterli ve güvenilir araçlar olduğuna karar verdi.

Dalgacık dönüşümü uzantısı olan S dönüşümü adı verilen bir başka ilginç dönüşüm, Dash ve ark. [3] tarafından önerildi. S dönüşümü pek çok vaat eden etkileyici zaman-frekans çözünürlüğü özelliklerine sahip olduğu görüldü. S dönüşümünün daha belirgin özellikleri, yerelleştirilebilir ve ölçeklenebilir Gauss penceresinin genişlemesi ve çevirilmesi sırasında ayarlayıcı sinüzoidlerin zaman eksenine göre sabit olmasından kaynaklandı.

Kanitpanyacharoea ve Premrudeepreechacharn [4], dalgacık dönüşümü ve yapay sinir ağlarını (Artificial Neural Network, ANN) kullanarak güç kalitesi problemi sınıflandırması üzerine bir sistem geliştirdi. Sinir ağları ile birlikte dalgacık dönüşümü kullanımını öneren sistemle güç kalitesi problemlerinde 6 güç kalitesi sınıfını doğru olarak sınıflandırabildi. Bu sistemin % 97,9 başarıya ulaştığı görüldü.

Kim ve ark. [5] çeşitli enerji kalitesi bozulmalarının tespiti ve sınıflandırılması için bir dalgacık tabanlı sinir ağı yöntemi geliştirdi. Önerilen sistem dalgacık ağı dalgacık dönüşümü özelliklerini ve sinir ağlarının avantajlarını birleştirdi. Özellikle tanıma seviyesini geliştirmek için ek özellik çıkarımı düşünüldü. Bu sistemde, db4 ayrık dalgacık dönüşümü ve ek özellikler, kısa ve orta süreli bozuklukları saptamak için kullanıldı. Radyal taban fonksiyonu sinir ağı daha hızlı eğitilebilir olması ve sınıflandırma yapmak kolay olduğu için tercih edildi.

Kaewarsa ve Attakitmongcol [6] çeşitli geçici olaylar altında uygulanan ve test edilen güç kalitesi bozulmalarını tanımak için bir dalgacık tabanlı sinir ağı sınıflandırıcısı önerdi. Ayrık dalgacık dönüşümü tekniği, güçlü bir sınıflandırıcı olan bir öğrenme vektör niceleme ağı kullanan çoklu sinir ağlarıyla birlikte kullanıldı. Bu çalışmada sunulan dalgacık tabanlı sinir sınıflandırıcısı, 6 tür güç kalitesi bozulmasını tanımlamak için tasarlandı. Sınıflandırıcıyı eğitmek ve test etmek için bozulma kayıtlarının toplam sayısı sırasıyla 780 ve 660 olarak belirtildi.

Tong ve ark. [7] dalgacık paketinin ayrıştırılmasına dayanan ve güç kalitesi bozulmalarının tespiti ve sınıflandırılması için destek vektör makinelerine (Support

Vector Machine, SVM) dayanan yeni bir yöntem önerdi. Dalgacık paket ayrıştırması esas olarak güç kalitesi bozulmalarının özelliklerini çıkarmak için kullanıldı. Destek vektör makineleri ağırlıklı olarak çıkarılan özelliklere göre güç kalitesi bozulmalarını sınıflandırabilen çok sınıflı bir sınıflandırıcı oluşturmak için kullanıldı. Simülasyon ve analiz sonuçları, önerilen yöntemin yapay sinir ağına dayalı yöntemle karşılaştırıldığında daha yüksek doğru tanımlama oranına, daha iyi yakınsama özelliğine ve daha az eğitim süresine ulaşabileceğini gösterdi. Destek vektör makineleri kullanılarak % 97,25, yapay sinir ağı kullanılarak % 95,25 başarıya ulaşıldı.

Basu ve Basu [8] güç sistemi geçici bozukluklarını tanımlamak için sürekli dalgacık dönüşümünün uygulanmasını önerdi. Bu çalışmanın amacı, bozukluğun süresini doğru bir şekilde tespit etmeyi sağlayan alternatif bir güç kalitesi sinyal analizi yöntemini vurgulamaktı. Kısa süreli geçici frekansların birlikte aktığı yüksek frekans bandındaki dalgacık dönüşümünün konsantrasyon imzasının bozulma özelliklerine göre birbirinden çok farklı olduğu saptandı.

Hua ve ark. [9] karmaşık dalgacık dönüşümü ve radyal taban fonksiyonu sinir ağı üzerine kurulmuş güç kalitesi bozucu algılama ve sınıflandırma metodunu geliştirdi. Karmaşık destekli dikey dalgacıklar, bozucu sinyalin özellik bilgilerini çıkarmak için kullanıldı. Güç kalitesi problemlerini analiz etmek için birkaç yeni dalgacık birleşik bilgiyi kullanmayı önerdi. Dalgacık dönüşümü katsayılarından elde edilen özellik, güç kalitesi bozucu model sınıflaması için radyal taban fonksiyonu sinir ağına girildi. Simülasyon sonuçlarına bakarak, kompleks dalgacık dönüşümünün radyal taban fonksiyonu sinir ağıyla birleşmesinin sinyal tekillikliğine daha duyarlı olduğunu ve sinyal özelliği bilgisi edinmek için önemli iyileşme sağladığını tespit edildi.

Hernandez-Perez ve ark. [10] mekanik sistemlerin dinamik sinyallerinin yüksek frekans dalgacık analizine dayalı olarak, soğuk ışıklı bir lambanın elektrik sinyaline çok çözünürlüklü dalgacık analizi yaptı. Bu çalışmada, harmoniklerin zamanla kendini tekrar etmediği gösterildi. Aynı zamanda, farklı genlikteki harmonikler aynı frekansta bulunabildiği görüldü. Güç kalitesi analizi için Morlet ana dalgacığın ve Daubechies filtrenin uygun olduğu bulundu.

Jayasree [11] frekans alanı, zaman alanı dönüşümleri ve yapay sinir ağları kullanılarak güç kalitesi bozulmaları sınıflandırması için yeni bir yaklaşım önerdi. Sinyallerin spektral katsayıları ayrık fourier dönüşümü, hızlı fourier dönüşümü, kısa zamanlı fourier dönüşümü ve ayrık dalgacık dönüşümü kullanılarak elde edildi. Spektral analiz ile birlikte ortalama, otokorelasyon, norm, standart sapma, enerji ve varyans gibi istatistiksel parametreler de bulundu. Bu parametreler, farklı güç sistemi olaylarını sınıflandırmak için yapay sinir ağlarına girdi olarak verildi. Goertzel Algoritmasının ayrık fourier dönüşümü bulmak için daha fazla hesaplama zamanı gerektirmekte olduğu tespit edildi. Hızlı fourier dönüşümü kullanılarak hesaplama süresi azaltılabileceği belirlendi. Fakat bu algoritmalar sadece periyodik sabit sinyaller için uygundu. Kısa zamanlı fourier dönüşümü, periyodik ve sabit sinyallere daha iyi uyuyor ancak sabit uzunluk gerektiriyordu. Dalgacık dönüşümü, değişken pencere uzunluğunu kullanan güç kalitesi sinyallerini analiz etmek için daha uygun olduğu tespit edildi.

Meyer [12] gürültülü ortamda güç kalitesindeki bozulmayı analiz etmek için dalgacık tabanlı özellik çıkarımı yapan ve bulanık sınıflandırma yöntemi kullanan bir sistem geliştirdi. Gürültünün giderilmesi, olayların algılanmasını basitleştirmek için ve özelliklerin çıkarılması için dalgacık dönüşümünden yararlandı. Bu özellikler olay türüyle ilgili karar vermek için bulanık sınıflandırıcı kullanılarak ayrıştırıldı. Bulanık ürün toplama mantığı kuralı kullanılmıştı ve gürültülü ortamda % 96,87'lik bir başarıya ulaşıldı.

Ruijuan ve Chunxia [13] geliştirilmiş geri yayılım algoritması ile kompleks dalgacık ağını tarayan dağıtım güç sisteminin kısa süreli bozulmasını saptamak için bir yöntem geliştirdi. Dalgacık dönüşümü katsayılarından elde edilen özellik, güç kalitesi bozulma örüntüsü tanıma için dalgacık ağına girildi. Güç kalitesi bozulma tanıma modeli oluşturuldu ve geliştirilmiş geri yayılım algoritması, ağ yapısını ve parametre tanımlamasını yerine getirmek için kullanıldı. Tanıma modelini eğitmek için yeterli sayıda örnek sinyal seçildi ve arızayı temsil eden test sinyali eğitimi ağı girince güç kalitesi bozukluğunun türü tespit edildi.

Chandel ve ark. [14] güç kalitesi bozulmalarını tanımak için bir dalgacık tabanlı yapay sinir ağı sınıflandırıcısı uygulamış ve test etti. Güç kalitesi problemi sınıflandırıcısını geliştirmek için ayrık dalgacık dönüşümü tabanlı çok çözünürlüklü sinyal ayrıştırma tekniği ve ileri beslemeli sinir ağı modeli ile birlikte kullanıldı. Güç kalitesi problemlerinin sınıflandırılması iki bölüm halinde gerçekleştirildi. Birinci bölümde, Parseval'ın enerji teoremi ile çok çözünürlüklü sinyal ayrıştırma analizi, güç kalitesi sinyalinin enerji özelliklerini çıkarmak için kullanıldı. İkinci bölümde, bu özellik bilgileriyle sinir ağı sınıflandırıcı çeşitli bozukluklarda test edildi

Nath ve ark. [15] ayrık dalgacık dönüşümünü, güç kalitesi bozulmalarını tespit etmek ve analiz etmek için kullandı. İlgilenilen güç kalitesi sorunları gerilim düşmesi, yükselmesi, kesilmesi ve dalgalanmasıydı. Özellik çıkarımı aşamasında dalgacık dönüşümünden yararlanıldı. Farklı seviyelerde dalgacık katsayıları, sinyalin değişimi hakkında bilgiyi yerelleştiren zamanı ortaya çıkardı.

Vega ve ark. [16] biorthogonal dalgacık fonksiyonunu, güç kalitesi bozukluklarının özellik çıkarımı için temel bir fonksiyon olarak kullandı. Ayrıca, bozuklukların büyüklüğünü karakterize etmek için karekök ortalama kare değeri kullanıldı. Her bir sınıflandırma şemasını eğitmek ve değerlendirmek için farklı bozulmalar ve farklı sinyal varyasyonları ile 19430 sentetik sinyalden oluşan bir veritabanı oluşturuldu. Aynı verilerin sınıflandırılması daha kısa sürdüğü için destek vektör makinası, bu çalışmada elde edilen desenler için en iyi sınıflandırıcı olarak tespit edildi. Fakat yapay sinir ağları ile yapılan sınıflandırmada daha iyi performans sonucu elde edildi.

Nath ve Sinha [17] bu çalışmada sinüzoidal olmayan koşullar altında güç bileşenlerini ayrık dalgacık dönüşümü kullanılarak hesaplandı. Güç bileşenlerinin geleneksel tanımları, sinüs olmayan koşullar altında uygun olmayacaktı bunun için bu çalışmada dalgacık dönüşümü tercih edildi. Daha sonra bulanık mantık güç sistemi bileşenleri ve güç kalitesi faktörünün belirlenmesi için uygulandı.

Zhao ve ark. [18] dalgacık analizi, FFT ve sanal deęer dalga formu karakteristiklerine dayanarak, yedi tip g¼ç kalitesi bozulmasını tespit etti. İlk olarak, gerilim sanal deęerinin boyutuna g¼re, bozukluklar iki t¼re ayrıldı, birinci tip gerilim ç¼kmesi, yükselmesi ve kesintiyi içerdi. İkinci tip g¼ç kalitesi bozulmalarının geri kalanını içerdi. Dalgacık analizi ikinci tip için gerçekleştirildi. Geçici darbe ve düşük frekanslı salınım, yüksek frekans katsayısının karakteristięi ile tanımlandı ve daha sonra sıfır geçiş noktalarının sayısı ile ayrıştırıldı. Yüksek frekans katsayısında benzer dağılım gösteren bozukluklar için FFT kullanıldı. Spektrum karakteristięi ile tespit edildi.

Milchevski ve Taskovski [19] özellik çıkarımında dalgacık dönüşümünü kullandı ve ek olarak üç tane fazladan katsayı ilave etti. Sınıflandırma aşamasında destek vektör makinası yönteminden yararlandı ve % 99,71'lik bir performans elde etti.

Singh ve ark. [20] g¼ç kalitesi olaylarının tespiti ve lokalizasyonu için çift ağaç ayrık dalgacık dönüşümü tabanlı kompleks dalgacık dönüşümü teknięini kullanımını sundu. Kompleks dalgacık dönüşümü standart ayrık dalgacık dönüşümünün karmaşık deęerli uzantısı olarak belirlendi. Zayıf yönl¼lük ve faz bilgisinin bulunmaması gibi sınırlamaları mevcuttu. Yapay sinir ağları kullanılarak yapılan sınıflandırmada % 98,9 başarı elde edildi.

Khoa ve ark. [21] g¼ç kalitesi bozulmalarını dalgacık dönüşümü ve K en yakın komşu sınıflandırıcısı kullanarak sınıflandırmak için yeni bir yöntem önerdi. Sinyalin minimum, ortalama ve maksimum deęeri ve bunlara ilave altı dalgacık dönüşümü temelli özellik çıkarıldı. K en yakın komşu (K nearest neighbor, KNN) algoritmasıyla yapılan sınıflandırmada %94,44'l¼k bir başarı elde edildi.

Upadhyaya ve Mohanty [22] farklı g¼ç kalitesi bozukluklarını saptamak ve lokalize etmek için çok ç¼zünürl¼kl¼ analiz teknięini uyguladı. On çeşit g¼ç kalitesi olayları hem ayrık dalgacık dönüşümü hem de ikinci nesil dalgacık dönüşümü kullanılarak analiz edildi. Her sinyal, dörd¼nc¼ seviyeye kadar ayrıştırıldı. İkinci nesil dalgacık dönüşümünde daha iyi sonuçlar elde edildi.

Tuljapurkar ve Dharne [23] güç kalitesi bozulmalarını tespiti için dalgacık dönüşümünü kullandı. Bozuklukların doğru sınıflandırılması için modüler yapay sinir ağı (Modular Artificial Neural Network, MANN) tekniği tercih edildi ve %98'lik bir başarıya ulaşıldı.

Kamble ve Dupare [24] çeşitli güç kalitesi bozulmalarının sınıflandırılmak, sınırlandırmak ve araştırmak için yeni bir yaklaşım oluşturdu. Gerilim çökmesi, yükselmesi, dalgalanması ve harmonikler, bu çalışmada gösterilen ana güç kalitesi problemleriydi. Bu çalışmadaki yaklaşım, dalgacık dönüşümü analizi, özellikle de ayrı dalgacık dönüşümü üzerine kuruldu. Ana fikir, verilen sinyali ayrı dalgacık dönüşümü kullanarak parçalara ayırmaktır. Bu ayrışan sinyaller özellikleri çıkarmak için kullanıldı. Bu özellikler, güç kalitesi bozukluklarını sınıflandırmak için yapay sinir ağına aktarıldı ve sınıflandırma yapıldı.

Shinde ve ark. [25] dalgacık dönüşümü kullanıldığı bir gerilim bozulma saptama tekniği önerdi. Kondansatör anahtarlama ve arızalar için elde edilen sonuçlar, MATLAB kullanılarak yapılan dalgacık analizi için kullanıldı. Farklı çalışma koşullarında üretilen benzetim sonuçları sunulan yöntemin etkinliğini gösterdi.

Naik ve Kundu [26] farklı güç kalitesi bozulmalarını analiz etmek için dalgacık paket dönüşümünün yetenekleri kullandı. Farklı güç kalitesi bozukluklarını analiz etmek için yeni bir istatistiksel değişken tanımlanmış ve hesaplandı. Yeni tanımlanan değişken, dalgacık paket dönüşümü ayrıştırılmalarının ortalama sapmasına dayanmaktaydı. Önerilen değişkenin ayrışma seviyesindeki değeri, sinyaldeki mevcut güç kalitesi bozulma tipi hakkında bilgi verdi.

Sebastian ve DSA [27] normal güç kalitesi bozuklukları için dalgacık dönüşümüne dayanan bir sınıflandırma sistemi sundu. Sınıflandırma algoritması için kullanılan parametre, dalgacık dönüşümünün ayrıntılı katsayısının onuncu seviye ayrıştırılmasının enerjinin dağılımıydı. Dalgacık dönüşüm parametrelerinin bozucu dalga formlarının sınıflandırılmasında etkili olduğu tespit edildi. Tatmin edici sonuçlar

yapay sinir ağı sınıflandırma amacıyla kullanıldı ve sonuçta % 88,44'lük bir başarı sağlandı.

Ijaz ve ark. [28] dalgacık dönüşümü tabanlı optimize edilmiş yapay sinir ağı kullanılarak güç kalitesi bozulmalarını saptamak ve sınıflandırmak için yeni bir yaklaşım sundu. Önerilen algoritmada, dalgacık dönüşümünün yaklaşık ve detay katsayılarını içeren enerji temelli özellik vektörü çıkarıldı. Güç kalitesi bozukluklarını sınıflandırmak için yapay sinir ağları tabanlı sınıflandırıcı kullanıldı. Önerilen yaklaşımın çok yönlülüğünü incelemek için altı farklı güç kalitesi bozukluğu incelendi. Ayrıca diferansiyel evrim kullanarak yapay sinir ağlarının ağırlıklarını optimize etmek için yeni ve yenilikçi bir yaklaşım kullanılarak % 99,83 başarı elde edildi.

Alshahrani ve ark. [29] güç kalitesi bozukluklarına ait özellikleri farklı frekanslarda süzmek, algılamak ve çıkarmak için dalgacık yöntemini kullandı. Ayrık dalgacık dönüşümü tarafından çıkartılan özelliklerin eğitimi ve güç kalitesi bozulmalarını sınıflandırmak aşaması yapay sinir ağları kullanılarak yapıldı. Bir gizli katmanı olan yapay sinir ağlarında %90 civarında başarı ve iki gizli katmanı olan yapay sinir ağlarında %91 civarında başarı elde edildi.

Khokhar ve ark. [30] ayrık dalgacık dönüşümü ve modüler olasılıksal sinir ağı (Modular Probabilistic Neural Network, MPNN) kullanılarak, tekli ve melez güç kalitesi bozukluklarının otomatik algılanması ve sınıflandırılmasına yönelik yeni bir yaklaşım sundu. Ayrıntı ve yaklaşık katsayılarından çıkarılan entropi ve enerji özellikleri, otomatik sınıflandırma işlemi gerçekleştirmek için modüler olasılıksal sinir ağına eğitim ve test verileri olarak uygulandı. Simülasyon sonuçları, sınıflandırıcının doğruluk ve güvenilirlik bakımından çok iyi bir performansa sahip olduğunu gösterdi.

Bhuiyan ve ark. [31] güç kalitesi bozulmalarını saptamak için dalgacık paketinin bozunumuna (Wavelet Packet Decomposition) dayalı akıllı şebeke güç kalitesi izleme sistemi için bir yöntem önerdi. Bu çalışmada, dalgacık paket katsayılarının iç ve ara

ölçek korelasyonuna dayanan güç kalitesi bozulmalarının tespiti için etkili bir teknik oluşturuldu. Dalgacık paket katsayıları yalnızca kendi ölçeğinde değil aynı zamanda bitişik ölçekler arasında da ilişkili olduğu bulundu.

Singh ve ark. [32] bu çalışmada, zaman kalite ve frekans alanında haritalanmış bir sinyalin dalgacık enerjisi dağılımı vasıtasıyla ve ayrık dalgacık dönüşümü kullanılarak güç kalitesi izlemesi önerdi. Gerilim kesintisi, çökmesi ve yükselmesi gibi güç kalitesi sorunları bir zaman penceresinde işlendi. Önerilen algılama algoritması, bozukluğun anlamlı bir şekilde tespit edilmesini sağladı.

Naik ve ark. [33] güç kalitesi olaylarını dalgacık paket dönüşümü (Wavelet Packet Transform, WPT) ve aşırı öğrenme makineleri (Extreme Learning Machines, ELM) kullanarak sınıflandırmak için yeni bir yöntem önerdi. Bu özellikler hem tekli hem de eşzamanlı güç kalitesi olayı oluşumlarını ayırdı. Sınıflandırma performansını arttırmak için ayrıca aşırı öğrenme makineleri tabanlı sınıflandırıcı kullanıldı. Bu sınıflandırıcı eğitim süresini çok azaltı. Sonuçta % 99,3 başarı elde edildi.

Sharma ve ark. [34] güç kalitesi ilişkili güç sistemi operasyonel olaylarını ve güç kalitesi bozulmalarını tespit etmek için ayrı bir dalgacık dönüşümü temelli teknik sundu. Gerilim yükselmesinin, yükün kesilmesi, kapasitör bankının açılması ve jeneratörün kapatılması ile bağlantılı olduğu gözlemlendi. Gerilim düşmesi, iletim hattının açılması ile ilişkilendirildi. Gerilim ve akımın harmonik bozulmaları tüm olaylarda gözlemlendi. Kapasitör anahtarlamasının ardından geniş alana ait şebeke kesintisi ile maksimum bozulma gözlemlendi.

Liu ve ark. [35] güç kalitesinde bozulmalarının sınıflandırılması için grup ampirik mod ayrıştırma (Ensemble Empirical Mode Decomposition) ve çok sınıflı öğrenme temelli için bir kombinasyon yöntemi geliştirdi. Sıra dalgacık destek vektör makinesi (Rank Wavelet Support Vector Machine, RWSVM) bozulmaların sınıflandırılmasında uygulandı. Sonuçta % 92,8 başarı elde edildi.

Thiyagarajan ve Subramaniam [36] güç kalitesi bozulmalarını saptamak için, öznelik çıkarma sürecinde ayrık dalgacık dönüşümü kullandı. Güç bozukluklarının sınıflandırılması için destek vektör ağları kullandı. Sonuçta gerilim kesintisi tespitinde % 99, gerilim çökmesi tespitinde % 94 ve gerilim yükselmesi tespitinde % 75 başarı sağlandı

Tomak ve Mengi [37] gerilim çökmesi ve kesintisini tespit eden bir sistem tasarımı için bir yöntem önerdi. Özellik çıkarımı için Haar dalgacık ailesi kullanılarak beşinci seviye dalgacık ayrışımı yapıldı. Sınıflandırma için kompleks ağaç yöntemi kullanıldı. Bunun nedeni kompleks ağaç sınıflandırma yönteminde tahmin hızının çok hızlı olması, bellek kullanımının az ve yorumlanabilirliği kolay olması olarak belirtildi. Eğitim aşamasında %88,6 ve test aşamasında % 86,4 başarı elde edildi.

Bosnic ve ark. [38] dalgacık dönüşümü ve destek vektör makinesi temelli güç kalitesi bozulmalarının sınıflandırılması için etkili bir yaklaşım sundu. Ayrışma katsayılarını elde etmek için bozucuları içeren sinyale altıncı seviye dalgacık dönüşümü uygulandı. Destek vektör makinesi kullanılarak yapılan sınıflandırmada %98,69 başarı elde edildi.

Markovska ve ark. [39] güç kalitesi sorunlarının tespit için rastgele orman (Random Forest, RF) sınıflandırıcıyı önerdi. Özellik çıkarımında ayrık dalgacık yönteminden yararlandı. Sınıflandırmada 7 adet güç kalitesi sorunu kullanıldı ve % 98,71 başarı elde edildi.

Harmoniklerin tespiti Akaike Bilgisi Kriterini kullanıldığı bir yöntem Tomak ve Mengi [40] tarafından önerildi. Sınıflandırma için k en yakın komşu algoritması kullanıldı. Bu algoritmanın hızlı ve harmoniklere yeterince hızlı tepki verdiği görüldü. Eğitim aşamasında % 94,8 ve test aşamasında % 91,7 başarı elde edildi.

BÖLÜM 2. GÜÇ KALİTESİNDE BOZUKLUKLAR

Herhangi bir güç sorunu, cihazların arızalanmasına veya yanlış çalışmasına neden olan gerilim, akım veya frekans sapmaları ile kendini gösterir. Bu bölümde sınıflandırılacak olan çeşitli güç kalitesi bozuklukları anlatılmaktadır. Tablo 2.1’de güç sistemleri için elektromanyetik olay sınıfları ve özellikleri verilmektedir [41].

Tablo 2.1. Güç sistemleri için elektromanyetik olay kategorileri ve özellikleri [41].

Sınıflar	Tipik Spektral İçerik	Tipik Süre	Gerilim Genliği
1. Geçici Olaylar			
1.1. Darbeli			
1.1.1. Nanosaniye	5 ns yükseliş	<50 ns	
1.1.2. Mikrosaniye	1 µs yükseliş	50 ns-1 ms	
1.1.3. Milisaniye	0,1 ms yükseliş	>1 ms	
1.2. Titreşimli			
1.2.1. Alçak frekans	<5 kHz	0,3-50 ms	0-4 pu
1.2.2. Orta frekans	5-500 kHz	20 µs	0-8 pu
1.2.3. Yüksek frekans	0,5-5 MHz	5 µs	0-4 pu
2. Kısa süreli değişimler			
2.1. Ani			
2.1.1. Kesinti		0,5-30 çevrim	<0,1 pu
2.1.2. Azalma		0,5-30 çevrim	0,1-0,9 pu
2.1.3. Artma		0,5-30 çevrim	1,1-1,8 pu
2.2. Anlık			
2.2.1. Kesinti		30 çevrim-3 s	<0,1 pu
2.2.2. Azalma		30 çevrim-3 s	0,1-0,9 pu
2.2.3. Artma		30 çevrim-3 s	1,1-1,4 pu
2.3. Geçici			
2.3.1. Kesinti		3 s-1 dakika	<0,1 pu
2.3.2. Azalma		3 s-1 dakika	0,1-0,9 pu
2.3.3. Artma		3 s-1 dakika	1,1-1,2 pu
3. Uzun süreli değişimler			
3.1. Kesinti		>1 dakika	0 pu
3.2. Gerilim düşmesi		>1 dakika	0,8-0,9 pu
3.3. Gerilim artması		>1 dakika	1,1-1,2 pu
4. Gerilim dengesizliği		Sürekli hal	0,5- % 2
5. Dalga biçimi bozulmaları			

5.1. DC ofset		Sürekli hal	% 0,1- % 0,5
5.2. Harmonikler	0-100. harmonik	Sürekli hal	0- % 20
5.3. Araharmikler	0-6 kHz	Sürekli hal	0- % 2
5.4. Çentik		Sürekli hal	
5.5. Gürültü	Geniş bant	Sürekli hal	0- % 1
6. Gerilim dalgalanmaları	<25 Hz	Sürekli hal	0,1- % 7
7. Güç frekansı değişimleri		<10 s	

NOT : s = saniye (second), μ s = microsaniye (microsecond), ns = nanosaniye (nanosecond), ms = millisaniye (millisecond), Hz = Hertz, kHz = kilohertz, MHz = megahertz, min = dakika (minute), pu = birim başına (per unit).

2.1. Harmonikler

Harmonikler, besleme geriliminin verileceği frekansın katları olan frekanslara sahip sinüzoidal dalga biçimleri olarak tanımlanabilir. Genellikle yük ve cihazların doğrusal olmayan özellikleri nedeniyle üretilmektedir. 50 Hz'lik bir sistemde, 2. derece harmonikleri (100 Hz), 3. derece harmonikleri (150 Hz), 4. derece harmonikleri (200 Hz) içerebilir. Normalde, 3 fazlı güç sisteminde sadece tek dereceden harmonikler meydana gelir. 220V bir prize bir osiloskop bağladığımızda, osiloskop ekranındaki görüntü genellikle mükemmel bir sinüs dalgası şeklinde değildir. Negatif ve pozitif maksimum değerlerinin yakın değerlerinde sinyal biraz düzleşebilir veya sarkabilir. Veya sinüs dalgası aşırı değerlerin yakınında daralabilir ve dalga biçimi sivri bir şekilde görünür. Her döngüde sinüs dalgası özellikle belirli noktalarda mükemmel yapısından sapar [42]. Örnek olarak Şekil 2.1.a'nın harmonik kısmını matematiksel olarak denklem 2.1'deki gibi ifade edebiliriz [43].

$$y(x) = \sin(x) + A * \sin(3x) + B * \sin(5x) + C * \sin(7x) \quad (2.1)$$

$y(x)$ = Harmonik titreşimi içeren sinyal, A, B, C= Katsayılar

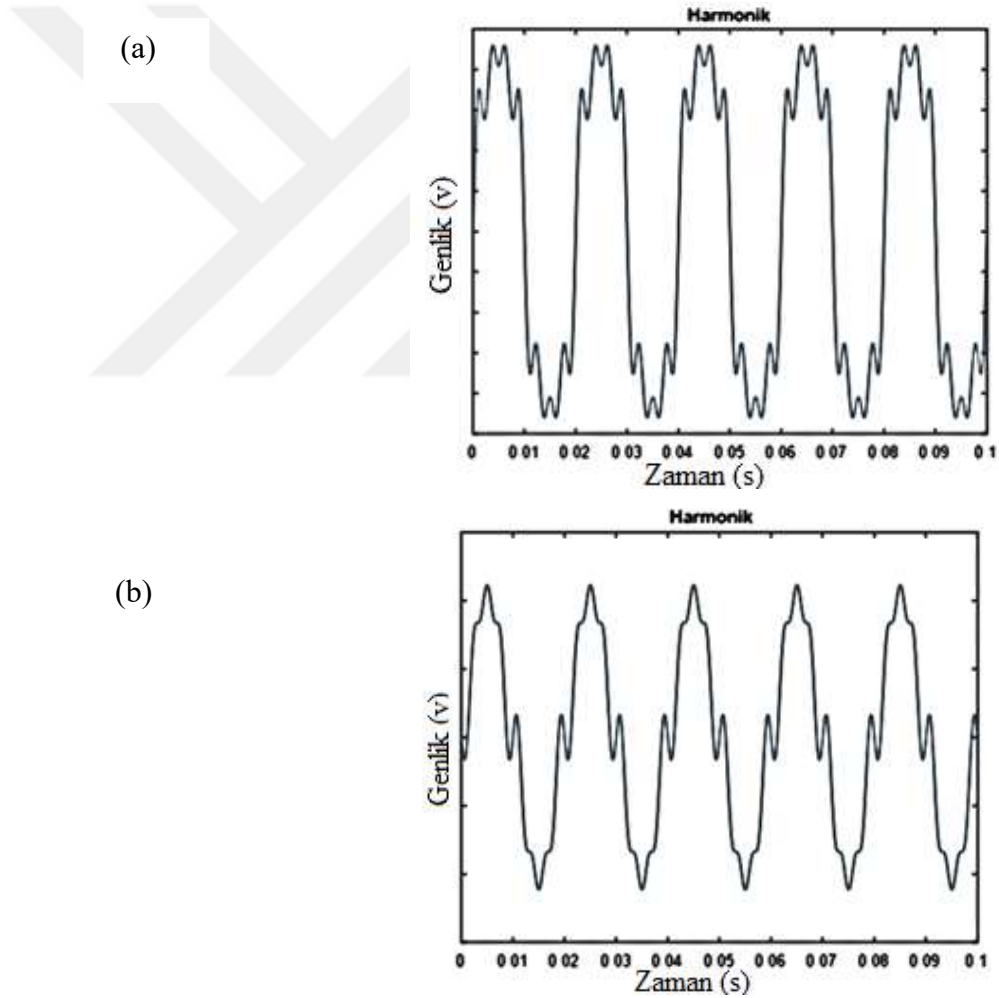
Bu denklemde 50 Hz sinüs dalgası ile frekansı 3 kat büyük ama genliği A katı olan sinüs dalgası toplanıyor. Bu toplama frekansı 5 kat büyük ama genliği B katı olan başka bir sinüs dalgası ve frekansı 7 kat büyük ama genliği C katı olan başka bir sinüs dalgası daha ekleniyor. Bu çoklu harmonik içeren sinyalin MATLAB kullanarak çizdirilmiş hali Şekil 2.1.a'da verilmiştir.

Benzer olarak harmonik kısmını matematiksel olarak denklem 2.2’de ifade ettiğimiz sinyali MATLAB kullanarak çizdirirsek Şekil 2.1.b’deki gibi bir sinyal elde ederiz [43].

$$y(x) = \sin(x) - A * \sin(3x) - B * \sin(5x) - C * \sin(7x) \quad (2.2)$$

$y(x)$ = Harmonik titreşimi içeren sinyal, A, B, C= Katsayılar

Bu dalga formu, temel frekans ile aynı fazda olmayan üçüncü, beşinci ve yedinci harmoniklere sahiptir. Toplama yerine çıkartma yapmamız, dalga formunda çok farklı bir görünüm üretmektedir.



Şekil 2.1. Denklem 1 ve 2’ye ait harmonik içeren örnek sinyaller.

Harmonik gerilimler, güç sisteminin temel frekansından oldukça yüksek frekanslara sahip harmonik akımlar ürettiği için, bu akımlar, güç sistemi boyunca ilerledikçe, temel frekans akımından daha yüksek empedanslarla karşılaşılırlar. Bunun nedeni yüksek frekans akımlarının iletken yüzeyinin yakınına akma eğilimi olan deri etkisi (skin effect) nedeniyle ortaya çıkmaktadır. Yüksek frekans akımının az bir kısmı iletken yüzeyinin çok altına nüfuz ettiğinden akım tarafından daha az kesit alanı kullanılır. İletkenin etkin kesiti azaltıldığında iletkenin etkin direnci artar. Harmonik akımların karşılaştığı daha yüksek direnç, iletkenin önemli derecede ısınmasına neden olur. Bu artan ısıtma etkisi çoğu zaman güç sisteminin iki özel bölümünde fark edilir: nötr iletkenler ve transformatör sargıları. Üç sayısının tek katlarına sahip harmonikler (3, 9, 15 gibi) sıfır sıralı akımlar gibi davrandıkları için özellikle zahmetlidirler. Sistemde üçgen bağlantılı transformatör sargılarında dolaşırlar ve bu sayede ilk çalışmada aşırı ısınma meydana gelmesine neden olurlar [42].


Elektromanyetik dalga üreten daha fazla teçhizatın elektrik sistemlerine eklenmesiyle, harmonikler şüphesiz daha endişe verici olmaya devam edecektir. Ancak, sistemin ilk tasarımı sırasında yeterince düşünülürse, harmoniklerin zararlı etkileri ortadan kaldırılabılır. Ayrıca harmoniklerden kurtulmak için değişik yöntemler mevcuttur. Bir yöntem harmonik dalga formlarının büyüklüğünü genellikle filtreleyerek azaltmaktır. Harmonik filtreler, bir güç faktörü düzeltme kondansatörü (C) ile seri olarak bir endüktans (L) eklenerek oluşturulabilir. L-C serisi devre, harmoniğe yakın bir frekans için ayarlanabilir. Filtreyi bu şekilde ayarlayarak, istenmeyen harmoniği azaltabiliriz. Diğer bir yöntem, harmonikleri daha etkin bir biçimde üstesinden gelebilecek sistem bileşenlerini kullanmaktır. Bir invertörün anahtarlama açısı, çıkış voltajındaki bazı harmonikleri ortadan kaldırmak için önceden ayarlanabilir. Bu, invertör tarafından üretilen harmonikleri azaltmak için çok uygun maliyetli bir yöntemdir. Deri etkisi, harmonik akımların neden olduğu artan ısıtmadan sorumlu olduğundan, daha geniş yüzey alanlı iletkenlerin kullanılması ısıtma etkilerini azaltacaktır. Bu ince şeritli iletkenler kullanılarak yapılabilir, çünkü iletkenin etkili yüzey alanı her bir telin yüzey alanı toplamıdır. K-faktör transformatörler olarak adlandırılan özel olarak tasarlanmış transformatörler, harmonik akımlar yaygın olduğunda kullanılabilir. Deri etkisini

azaltmak ve harmonikler tarafından üretilen daha yüksek akı frekanslarında doygunluk etkilerini azaltmak için özel tasarlanmışlardır [42].

2.2. Gerilim Çökmesi

Gerilim çökmesi rms gerilim büyüklüğünde anlık bir düşüştür, genellikle güç sisteminin herhangi bir yerindeki uzaktaki bir arızadan kaynaklanmaktadır. Gerilim çökmeleri birçok endüstriyel firmanın karşı karşıya olduğu en önemli güç kalitesi sorunlarından biridir. Modern endüstri tesislerinde kullanılan cihazların karmaşıklığı arttıkça gerilim çökmesine karşı daha hassas hale gelmektedir. Gerilim çökmesi genellikle arıza koşullarından kaynaklanır. Gerilim çökmelerine neden olan arızalar, tesis içinde veya şebeke sisteminde oluşabilir. Gerilim çökmesi durumu, arıza koruyucu bir cihaz tarafından düzeltilene kadar sürer. Tesiste, bu genellikle bir sigortadır. Tesisat sistemi arızaları dağıtım sistemi veya iletim sistemi üzerinde oluşabilir. İletim sistemindeki hatalar daha fazla müşteriye etkileyebilir [44].


Bir tesisat şebekesindeki arızaların büyük çoğunluğu faz-toprak arızalarıdır. Üç fazlı arızalar daha şiddetlidir, ancak çok daha az görülür. Büyük bir endüstriyel tesiste gerilim düşüşünün en sık nedeni yıldırımdır. Yıldırım hava ile ilgilidir ve hava bir mevsimden diğerine, bir yıldan diğerine son derece değişken olabilir. Ani yük değişiklikleri veya aşırı yükler gerilim çökmelerine neden olabilir. Trafo bağlantılarına bağlı olarak, enerjilenen transformatörler gerilim çökmelerinin başka bir nedeni olabilir. Elektrik motorları anma hızlarında çalıştıklarından daha fazla akım çektiğinden, bundan dolayı kalkış anında gerilim çökmesi olabilir. Gerilim çökmeleri elektrik şebekesinden gelebilir, ancak bunların çoğu bina içi cihazlardan kaynaklanır. Evlerde, buzdolapları, klima cihazları veya ocak fanları devreye girdiğinde gerilim çökmeleri görülebilir [45]. MATLAB kullanılarak hazırlanmış gerilim çökmesi içeren örnek bir sinyal Şekil 2.2’de verilmiştir.



Şekil 2.2. Gerilim çökmesi içeren örnek bir sinyal.

2.3. Gerilim Yükselmesi

Gerilim yükselmesi gerilim çökmesinin tam tersidir ve daha az oluşur. Gerilim yükselmesi, rms gerilim seviyesinin yarım devir süresinden bir 1 dakikaya kadar olan sürede normal değerın %110-180'ine yükselmesi olarak tanımlanır. Gerilimin ani bir artışı olan gerilim yükselmesi, bir güç sisteminde büyük güçlü bir yük devreden çıkarıldığında oluşur [46]. Bir gerilim çökmesinin etkileri daha belirgin olmasına rağmen, gerilim yükselmesinin etkileri genellikle daha yıkıcıdır. Gerilim yükselmesi güç kaynakları üzerindeki bileşenlerin bozulmasına neden olabilir, ancak etki yavaş yavaş birikebilir ve sonradan görülebilir. Aşırı ısınmaya bağlı olarak sistemin devre dışı kalmasına neden olabilecek kontrol sorunları ve cihazların donanım hatasına neden olabilir. Ayrıca, elektronik ve diğer hassas cihazlar gerilim yükselmesi nedeniyle hasar görmeye eğilimlidir. MATLAB kullanılarak hazırlanmış gerilim yükselmesi içeren örnek bir sinyal Şekil 2.3'de verilmiştir.



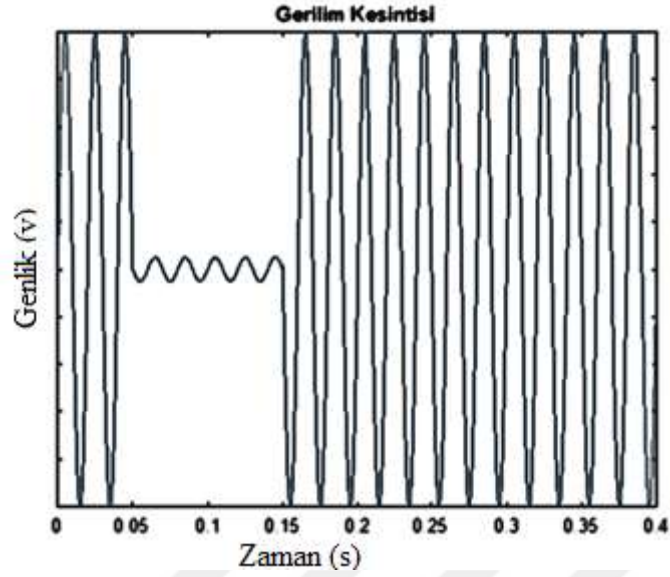
Şekil 2.3. Gerilim yükselmesi içeren örnek bir sinyal.

2.4. Gerilim Kesintisi

Gerilim kesintisi veya karartma, gerilimin normal gerilim değerinin %10'unun altına düştüğü durumdur. Genellikle kısa süreli olaylardır ve 30 saniyeden kısa sürerler. Kontrol sistemlerinin çalışmasında yanlışlık veya cihaz arızaları nedeniyle oluşabilmektedir. Kesintileri 3 kategoride sınıflandırabiliriz:

1. Anlık Gerilim Kesintileri (30 çevrim ile 3 saniye arasında)
2. Geçici Gerilim Kesintileri (3 saniye ile 1 dakika arası)
3. Sürekli Gerilim Kesintileri (1 dakikadan fazla)

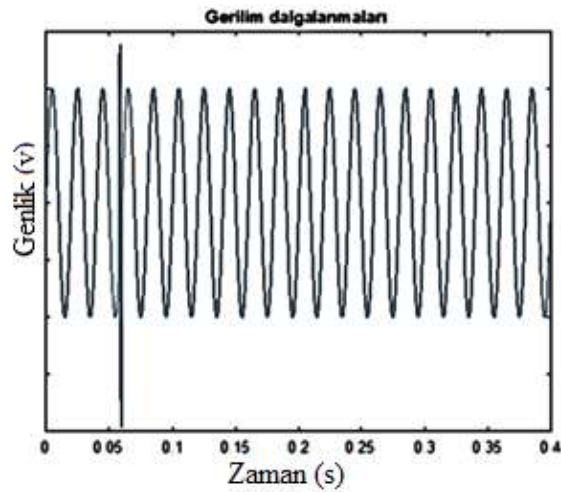
MATLAB kullanılarak hazırlanmış gerilim kesintisi içeren örnek bir sinyal Şekil 2.4'de verilmiştir.



Şekil 2.4. Gerilim kesintisi içeren örnek bir sinyal.

2.5. Gerilim Dalgalanmaları

Gerilim dalgalanmaları Şekil 2.5’de gösterildiği gibi genliği değişen kısa bir zamanlı bozukluklardır. Elektrikli cihazlara ciddi hasarlar verebilen gerilim darbesi olarak da ifade edilebilir. Yıldırım gibi hava olayları, ark arızaları ya da cihazın çalışması veya arızalanması nedeniyle oluşabilir. Zararlı etkilerinden korunmanın en iyi yolu, uygun boyutlarda endüstriyel sınıflı aşırı gerilim dalgalanma bastırıcı kullanılmasıdır. 10 mikrosaniye ile 100 mikrosaniyeye aralığındaki sürede, 20.000 volt'a kadar büyük bir gerilim tepesi olduğunda, gerilim dalgalanmaları meydana gelebilir. Çok kısa bir süre içinde gerçekleştiği için standart elektrik test cihazlarında görünmeyebilir.




Şekil 2.5. Gerilim dalgalanması içeren örnek bir sinyal.

2.6. Gerilim Titremesi

Gerilim titremesi (Fliker) çoğunlukla çok miktarda reaktif güç gerektiren yüklerde hızlı değişimden kaynaklanır. Fliker ölçülmesi ve giderilmesi zor bir güç kalitesi sorunudur. Fliker varlığı genellikle aydınlatma cihazlarında parlaklık değişiminin insanları rahatsız etmesiyle anlaşılır. Fliker gerilim miktarıyla değişebilir, ayrıca gerilimin frekansında fliker oluşumunda etkilidir [47]. Fliker sorunu bulunan sistemin gerilim şekli denklem 2.3'deki şekilde ifade edilebilir [43]. MATLAB kullanılarak hazırlanmış gerilim titremesi (Fliker) içeren örnek bir sinyal Şekil 2.6'da verilmiştir.

$$U(t) = (1 + a * \sin(b * \omega t)) * \sin(\omega t) \quad (2.3)$$

$U(t)$ = Gerilim titremesi içeren sinyal, a, b = Katsayılar, $\omega = 2\pi f$,
 f = frekans



Şekil 2.6. Gerilim titremesi (Fliker) içeren örnek bir sinyal.

BÖLÜM 3. DALGACIK TEORİSİ

Dalgacık teorisi, mühendislikte güçlü bir matematiksel araç olarak kullanılır. Dalgacıklar, bir sinyali hem zaman hem de frekans alanında temsil edebilen fonksiyonlardır. Dalgacık fonksiyonu Ψ denklem 3.1’de verilmiştir [48].

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0 \quad (3.1)$$

$\Psi(t)$ = Dalgacık fonksiyonu

Dalgacık fonksiyonu sıfır ortalamalı, normalize edilmiş ve $t = 0$ ’a göre ortalanmıştır. Dalgacık fonksiyonunu konvolüsyon çarpımı olarak yazılabilir [48].

3.1. Ayrık Dalgacık Dönüşümü

Dikey dalgacık taban fonksiyonumuz denklem 3.2’de verilmiştir.

$$\Phi_{(s,l)}(x) = 2^{\frac{-s}{2}} \Phi(2^{-s} x - l) \quad (3.2)$$

$\Phi_{(s,l)}(x)$ = Dikey dalgacık taban fonksiyonu, l = Konum indeksi,

s = ölçek indeksi

Ayrık dalgacıklar ailesini oluşturmak için ana fonksiyonu genişleten ve ölçekleyen değişkenler l ve s ‘dir. Konum indeksi l konumu verir ve ölçek indeksi s dalgacık genişliğini verir [49].

Analiz yapan dalgacık Φ , veri alanının farklı çözünürlüklerde yayılması için bir denklem 3.3’deki gibi bir ölçeklendirme denkleminde kullanılır.

$$W(x) = \sum_{k=-1}^{N-2} (-1)^k c_{k+1} \Phi(2x + k) \quad (3.3)$$


Φ = Analiz yapan dalgacık, $W(x)$ = Ölçekleme fonksiyonu,
 c_k = dalgacık katsayıları

Dalgacık katsayıları denklem 3.4 ve 3.5'deki koşulları sağlamalıdır [49].

$$\sum_{k=0}^{N-1} c_k = 2 \quad (3.4)$$

$$\sum_{k=0}^{N-1} c_k c_l = 2\delta_{l,0} \quad (3.5)$$

c_k ve c_l = dalgacık katsayıları, l = konum indeksi, δ = delta
fonksiyonu



Şekil 3.1. İkili (dyadic) ayrıştırma ağacı [50].


Şekil 3,1'de gösterilen ayrışma, ikili (dyadic) ayrıştırma ağacıdır. Sinyal, birinci düzeydeki yüksek ve alçak frekans bileşenlerine ayrılır. Enerjiyi en fazla içeren bu ilk düşük frekanslı alt bant, tekrar yüksek ve düşük frekanslı alt bantlara ayrıştırılır. Bu, K seviyesine kadar devam ettirilir [50].

3.2. Haar Dalgacık Fonksiyonu

Haar dalgacık fonksiyonu en basit yapıdaki dalgacık fonksiyonudur. Yeniden boyutlandırılmış, kare şeklinde fonksiyonların bileşkesi olup, birlikte bir dalgacık ailesi oluşturur. Şekil 3,2’de gösterilen Haar dalgacık, tüm dikey dalgacıklar arasında en küçük desteğe sahiptir. Pürüzsüz fonksiyonları benzetmeye pek uygun değildir çünkü yalnızca sıfırlanan momenti vardır [48]. Haar dalgacık fonksiyonunu denklem 3.6’da verilmiştir.

$$\Psi(t) = \begin{cases} 1 & 0 \leq t < \frac{1}{2} \\ -1 & \frac{1}{2} < t \leq 1 \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.6)$$


$\Psi(t)$ = Haar dalgacık fonksiyonu



Şekil 3.2. Haar Dalgacık Fonksiyonu.

3.3. Daubechies Dalgacık Fonksiyonu

Daubechies dalgacık fonksiyonu verilen destek için maksimum sayıda sıfırlanan moment ile karakterize edilen dikey dalgacık aileleridir. Diğer bir şekilde ifade edersek herhangi bir sayıdaki sıfırlanan moment, minimum boyutta desteğe sahiptir [48]. Daubechies dalgacık fonksiyonları db2, db4, db6, db12 Şekil 3.3’de verilmiştir.



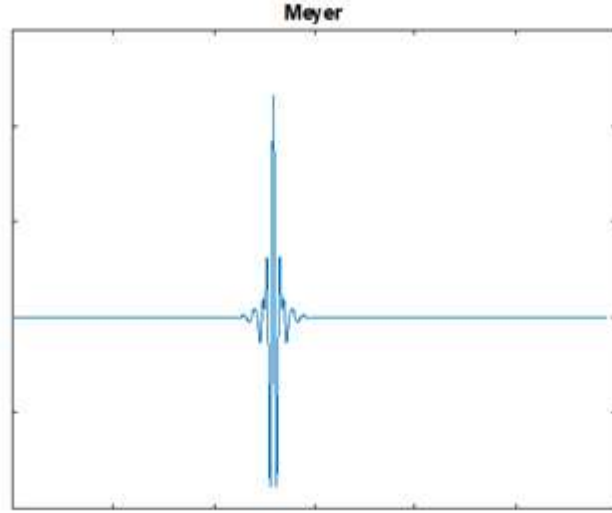
Şekil 3.3. Daubechies Dalgacık Fonksiyonu.

3.4. Meyer Dalgacık Fonksiyonu

Meyer dalgacık fonksiyonu düzgün bir Fourier dönüşümü olan frekans bandıyla sınırlı bir fonksiyondur. Bu akıcılık, zamanla çok daha hızlı bir asimptotik ayrışma sağlar [48]. Meyer dalgacık fonksiyonu denklem 3.7’de verilmiştir. MATLAB kullanılarak hazırlanmış Meyer dalgacık fonksiyonu Şekil 3.4’de verilmiştir.

$$\Psi(t) = \begin{cases} 2\Pi^{-\frac{1}{2}} & |t| < \frac{2\Pi}{3} \\ 2\Pi^{-\frac{1}{2}} \cos\left[\frac{\Pi}{2}v\left(\frac{3}{2\Pi}|t| - 1\right)\right] & \frac{2\Pi}{3} < |t| < \frac{4\Pi}{3} \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.7)$$

$$\Psi(t) = \text{Meyer dalgacık fonksiyonu,} \quad v(t) = \begin{cases} 0 & t \leq 0 \\ t & 0 < t < 1 \\ 1 & 1 \leq t \end{cases}$$

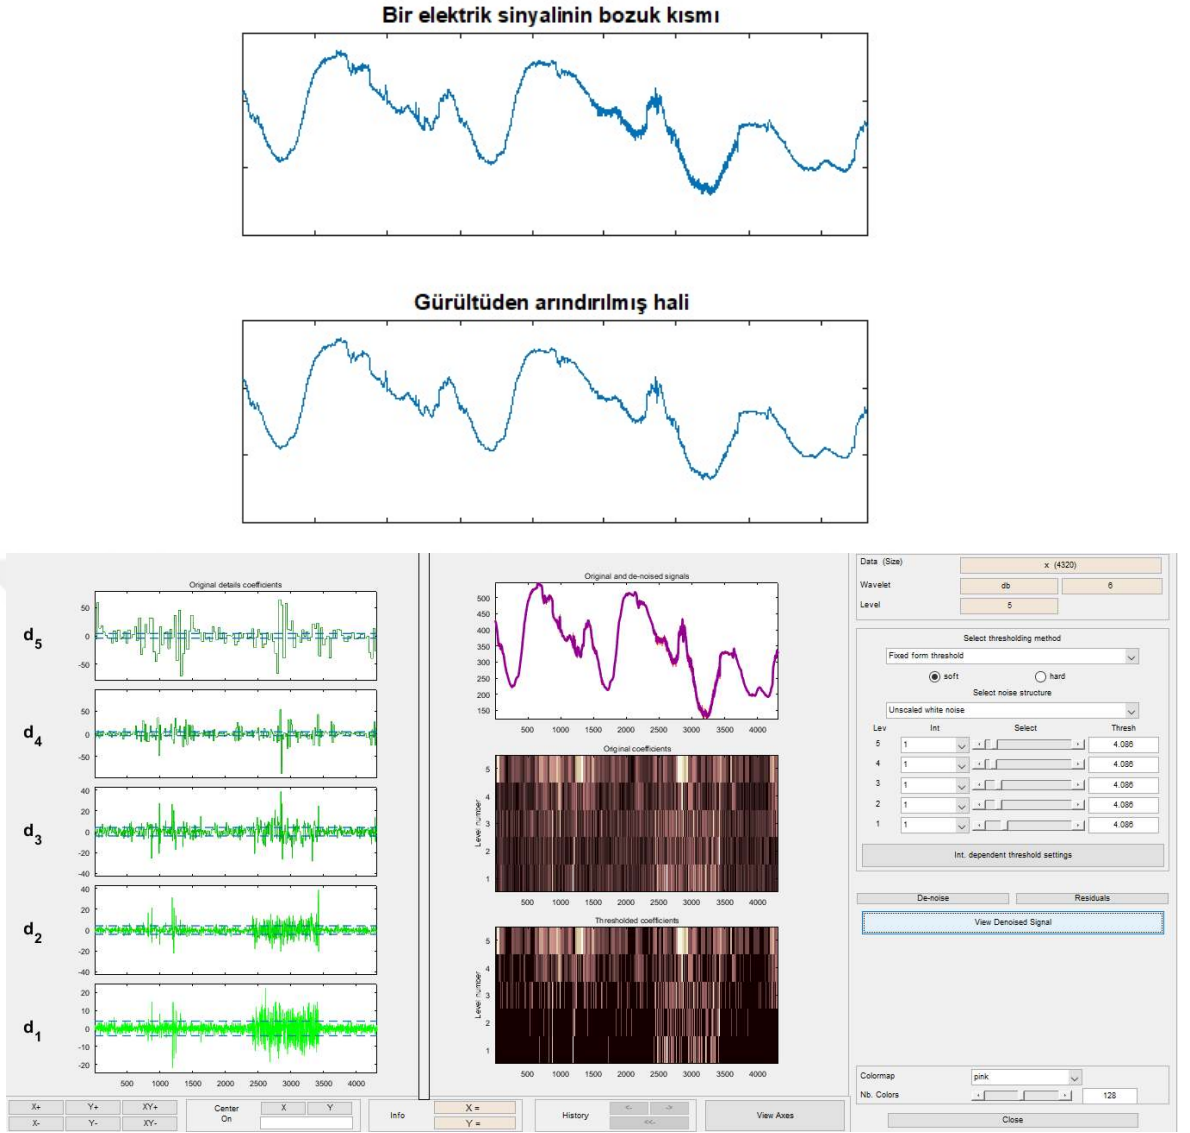


Şekil 3.4. Meyer Dalgacık Fonksiyonu.

3.5. Dalgacık Yöntemi Kullanılarak Gürültü Giderme

Gürültü giderme üç adımdan oluşur. Birinci adım ayrıştırma adıdır. Bir dalgacık seçilir, bir seviye seçilir. Seviye N'deki sinyalin dalgacık ayrışmasını hesaplanır. İkinci adımda 1'den N'ye kadar olan her seviye için bir eşik seçilir ve ayrıştırma katsayılarına yumuşak eşik değeri uygulanır. Üçüncü adımda N seviyesinin orijinal yaklaşık katsayıları ve 1'den N'ye kadar olan seviyelerin modifiye detay katsayılarını kullanarak dalgacık yeniden yapılanması tamamlanır [51].

Dalgacık yöntemi kullanılarak gürültü gidermede sinyal beşinci seviyede ayrıştırılmıştır. Daubechies 6 ana dalgacık olarak kullanılmıştır. Eşik belirlemede sabit yapıda eşik seçilmiştir. Gürültü yapısı ölçeklenmemiş beyaz gürültü olarak belirlenmiştir. Dalgacık yöntemi kullanılarak gürültü giderme süreci Şekil 3.5'de verilmiştir.

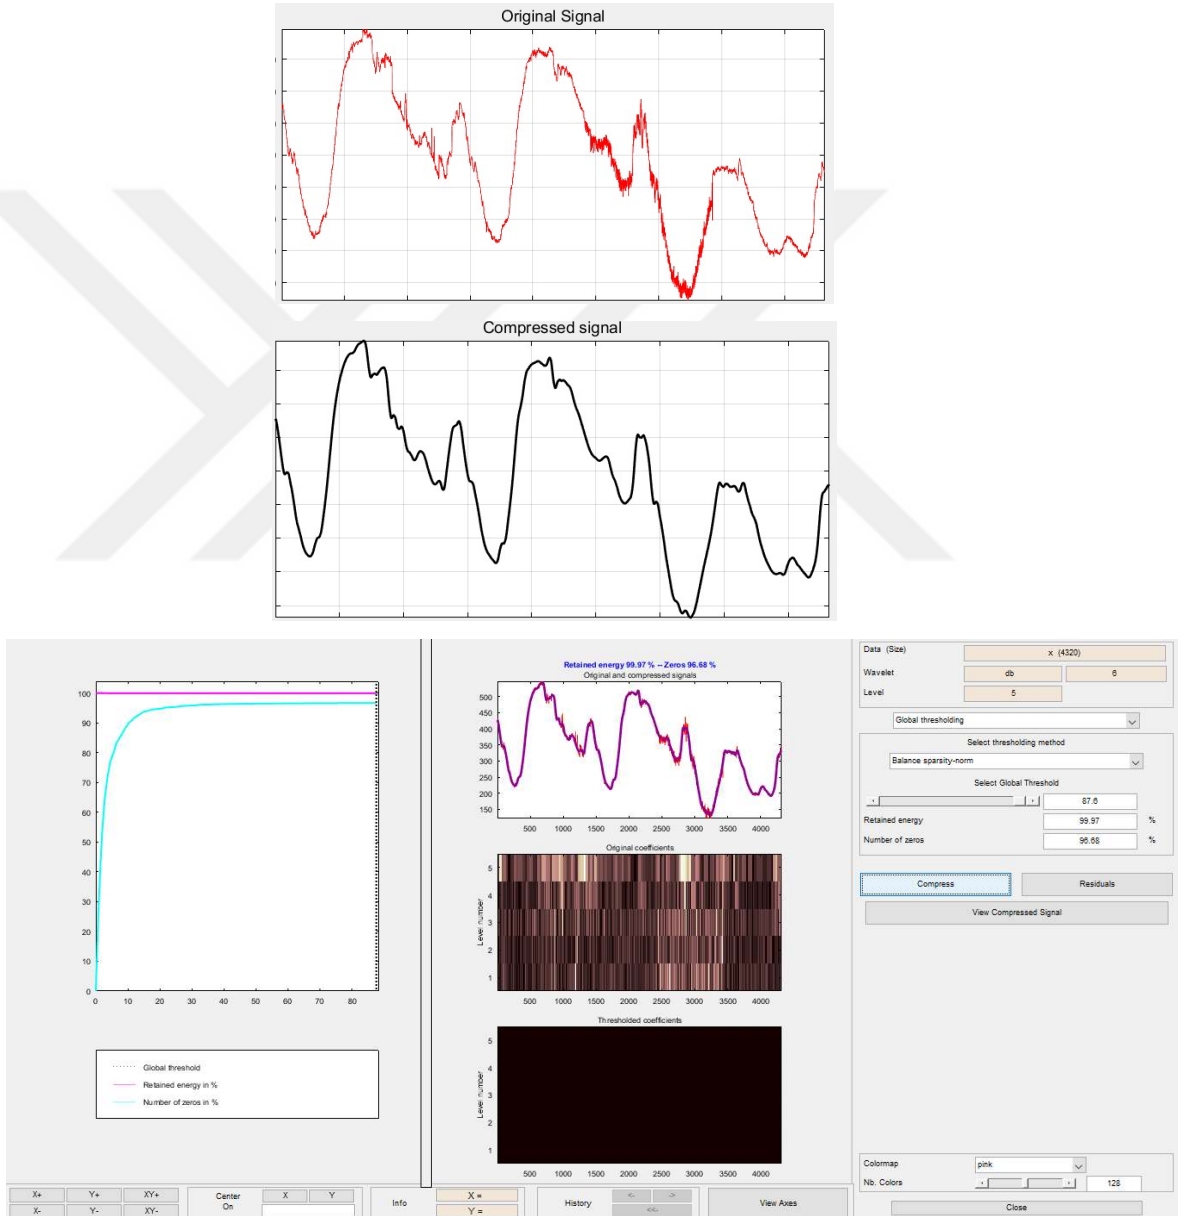


Şekil 3.5. Dalgacık Yöntemi Kullanılarak Gürültü Giderme

3.6. Dalgacık Yöntemi Kullanılarak Sıkıştırma

Dalgacık yöntemi kullanılarak sıkıştırmada katsayılar hesaplandıktan sonra belirli bir eşik değeri belirlenir. Bu eşikten küçük katsayılar göz ardı edilir. Dolayısıyla, sıkıştırılmış sinyal, kaydedildiğinde veya gönderildiğinde orijinal sinyalden daha az kaynak tüketir. Ters dönüşümü uygularsak, özgün belgeye benzer yaklaşık bir sinyal alırız. Bu, orijinal sinyalin özelliklerinin çoğunun sıkıştırılmış sinyalde depolanabileceği anlamına gelir.

Dalgacık yöntemi kullanılarak sıkıştırmada sinyal beşinci seviyede ayrıştırılmıştır. Daubechies 6 ana dalgacık olarak kullanılmıştır. Eşik değeri yöntemi olarak küresel eşik değeri kullanıldı. Bu yöntem sabit eşik yerleştirir. Küresel eşik için denge seyrekliği tercih edilmiştir. Dalgacık yöntemi kullanılarak sıkıştırma süreci Şekil 3.6'da verilmiştir.



Şekil 3.6. Dalgacık yöntemi kullanılarak sıkıştırma.

BÖLÜM 4. SINIFLANDIRMA

Veri bilimi, değerli bilgiyi elde etmek amacıyla verileri işlemek ve analiz etmek için kullanılan bir disiplindir. Veri bilimi, veri algılama ve toplama, veri saklama, veri işleme ve öznitelik çıkarımı, veri madenciliği ve bilgi keşfi de dâhil olmak üzere tüm süreci desteklediği anlamında bütüncül bir yaklaşımdır [51].

Veri madenciliği, ilginç ve önceden bilinmeyen kalıpları aramak için büyük veritabanları arasında geçiş yapma sürecini tanımlamak için üretilen bir terimdir. Veri madenciliğinin nihai hedeflerinden biri, belirli olaylarla ilgili tahminlerde bulunma becerisidir. Veri madenciliği tekniklerinin çoğu endüktif öğrenmeye dayanır. Endüktif yaklaşımın altında yatan varsayım, eğitilmiş modelin gelecekteki görünmeyen örneklere uygulanabilir olmasıdır. Bir model, yeterli sayıda eğitim örneğinden genelleme yapılarak açıkça veya üstü kapalı olarak oluşturulmuştur [51].

Sınıflandırma, sınıfı bilinen gözlemleri (veya örnekleri) içeren bir eğitim seti temelinde, yeni bir gözlemin ait olduğu sınıfın tanımlanması sorunudur. Sınıflandırma yapılabilmesi için özellik veya özelliklerin belirlenmesi gereklidir. Özelliklerin uygun seçilmesi sınıflandırma sürecini kolaylaştıracaktır. Bu çalışmada özellik olarak dalgacık dönüşümünden elde edilen katsayılar kullanılmıştır. Sonuçlar eğitim doğruluğu, test doğruluğu, özgünlük, hassaslık kavramları ile değerlendirilmiştir.

Doğruluk, özgünlük ve hassaslık tanımıyla birlikte yaygın olarak kullanılan birkaç terim vardır. Bu terimler gerçek pozitif (true positive, TP), gerçek negatif (true negative, TN), yanlış negatif (false negative, FN) ve yanlış pozitif (false positive, FP) olarak bilinir. Bir sinyalde mevcut bir bozukluk kanıtlanmışsa, verilen sonuç bozukluğun varlığını da gösterir, testinin sonucu gerçek pozitif kabul edilir. Benzer şekilde, eğer bir bozukluğun sinyalde bulunmadığı kanıtlanmışsa, sonuç da

bozukluğun var olmadığını gösterir, test sonucu gerçek negatiftir. Eğer, bozukluk olmayan bir sinyalde bozukluğun varlığını gösteriyorsa, test sonucu yanlış pozitifdir. Son olarak, bozukluk olan bir sinyalde bozukluğun bulunmadığını gösteriyorsa, test sonucu yanlış negatiftir. Hem gerçek pozitif hem de gerçek negatif, test ile kanıtlanmış durum arasında tutarlı bir sonuç olduğunu düşündürmektedir. Fakat yanlış pozitif ve de yanlış negatif test sonuçlarının gerçek durumun aksine olduğuna işaret eder. Hassaslık, test ile doğru olarak tanımlanan gerçek pozitiflerin oranıdır. Hassaslık, bozukluğun tespit edilmesinde testin ne kadar iyi olduğunu gösterir yani testin doğru tespit etme yeteneğini ifade eder. Özgünlük, gerçek negatiflerin doğru bir şekilde tanımsal test ile tanımlanan oranıdır. Özgünlük, testin bozukluk olmayan durumları doğru tespit edebilme yeteneği ile ilgilidir, bir diğer deyişle testin normal koşulu tanımlamada ne kadar iyi olduğunu göstermektedir. Doğruluk, gerçek sonuçların yani gerçek pozitif veya gerçek negatif değerlerinin toplam değerlere oranıdır. Tanı testinin doğruluğunu ölçer. Doğruluk, sistematik hataların bir tarifi, istatistiksel önyargı ölçütüdür [53]. Doğruluk, özgünlük ve hassaslık ifadeleri matematiksel olarak denklem 4.1, 4.2 ve 4.3’de verilmiştir.

$$Hassaslık = \frac{TP}{TP+FN} \quad (4.1)$$

$$Özgünlük = \frac{TN}{TN+FP} \quad (4.2)$$

$$Doğruluk = \frac{TP+TN}{TP+FP+FN+TN} \quad (4.3)$$

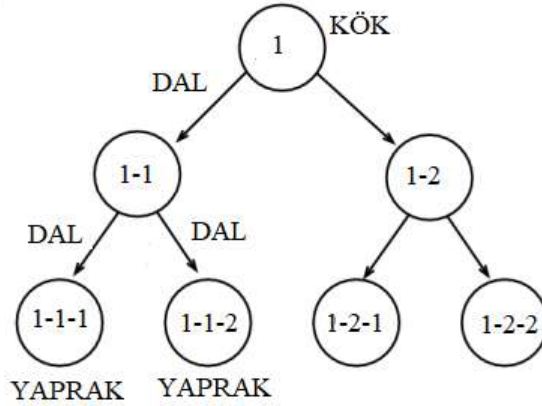
TP= Gerçek pozitif, TN= gerçek negatif, FN= yanlış negatif,
FP= yanlış pozitif

4.1. Basit Karar Ağacı

Karar ağaçları hızlı sınıflandırma için en iyi seçeneklerden biridir. Karar ağacı öğrenmesinde, bir öge hakkındaki gözlemlerden ögenin hedef değeri ile ilgili

sonuçlara gitmek için bir karar ağacı kullanır. Bu ağaç yapılarında yapraklar sınıf etiketlerini temsil eder ve dallar bu sınıf etiketlerine götüren özelliklerin birleşimlerini temsil eder.

Veri madenciliğinde bir karar ağacı, hem sınıflandırıcıları hem de regresyon modellerini temsil etmek için kullanılacak tahmini bir model iken, işlemlerdeki araştırma karar ağaçları hiyerarşik bir karar modeline ve sonuçlarına değinmektedir. Bir karar ağacı, örnek alanının yinelemeli bir bölümü olarak ifade edilen bir sınıflandırıcıdır. Karar ağacı, köklü ağacı oluşturan düğümlerden oluşur. Giden kenarları olan bir düğüme iç düğüm veya test düğümü denir. Diğer tüm düğümlere yapraklar adı verilir. Ayrıca bu düğümler uç düğümler veya karar düğümleri olarak da bilinir. Bir karar ağacında, her dâhili düğüm, örnek alanını, girdi özellik değerlerinin belli bir ayırık fonksiyonuna göre iki veya daha fazla alt alana böler. Her yaprak ise en uygun hedef değeri temsil eden bir sınıfa ayrılır. Alternatif olarak, yaprak, belirli bir değere sahip hedef özniteliğinin olasılığını belirten bir olasılık vektörünü tutabilir [52]. Örnek bir karar ağacı yapısı Şekil 4.1’de verilmiştir.



Şekil 4.1. Örnek bir karar ağacı.

Karar ağaçlarının yorumlanması kolaydır. Bellek kullanımını düşüktür. Ancak olası düşük öngörme doğruluğu onların ana dezavantajı olarak görülebilir. Gini'nin çeşitlilik endeksi, bölünme kistası olarak seçilmiştir. Gini endeksi, hedef öznitelik değerlerinin olasılık dağılımları arasındaki farkları ölçen, saf olmamaya dayalı bir ölçüttür.

Basit karar ağacı (Simple Tree) için model esnekliği düşüktür. Az yaprak içerir. Basit karar ağacı yapımız için maksimum bölünme sayısı 4 olarak seçilmiştir. Maksimum bölünme sayısı derinliği kontrol etme yolumuzdur. Eğer büyük bir değer alırsak işlemci üzerindeki yük ve hesaplama süresi artar. Model daha karmaşık bir yapı kazanır. Küçük bir değer seçilmesi sıg bir ağaç yapısı oluşturur. Modelin doğruluğu azalır. Ama hızlı karar verir. Basit karar ağacı için büyük bir değer seçemeyiz. Büyük değerler kompleks ağaç yapılarında kullanılır. Denemeler sonunda 4 değerini modelimiz için en uygun değer olduğuna karar verildi.

Tablo 4.1. Basit Karar Ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

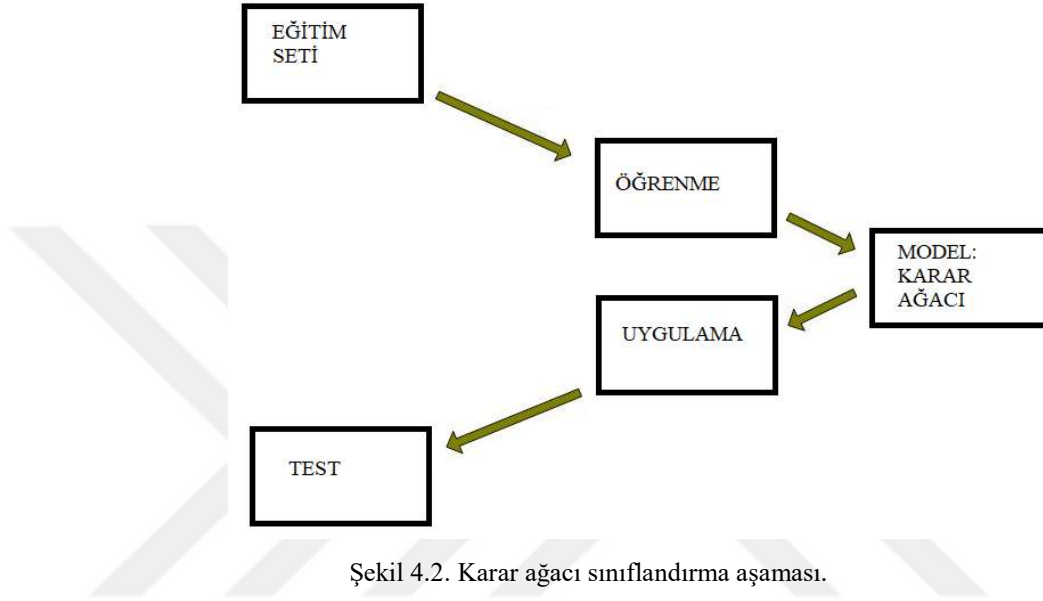
Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	83,0	0,40	1,00	81,5
Meyer	80,9	0,33	0,98	80,0
db2	77,7	0,27	0,98	77,5
db4	78,7	0,27	1,00	78,2
db6	83,1	0,45	0,98	81,9

Basit karar ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.1’de verilmiştir. Basit karar ağacından elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduğu görülmektedir. db6 dalgacığı ile yapılan analizde eğitim doğruluğu % 83,1 ve test doğruluğu % 81,9 olarak bulunmuştur.

4.2. Orta Seviye Karar Ağacı

Orta seviye karar ağacı (Medium Tree) için model esnekliği orta seviyedir. Orta seviyede yaprak içerir. Orta seviye karar ağacı yapımız için maksimum bölünme sayısı değeri 20 olarak seçilmiştir. Orta seviye küçük değerler kullanamayız. Büyük değerler ise kompleks ağaçlar içindir. Denemeler sonunda 20 değerini modelimiz için en uygun değer olduğuna karar verildi. Gini'nin çeşitlilik endeksi, bölünme kriteri olarak seçilmiştir.

Orta seviye karar ağacında diğer sınıflandırma sürecinde olduğu gibi eğitim sürecinde bir eğitim seti kullanılır ve bir model belirlenir. Model olarak bu aşamada orta seviye karar ağacı seçilmiştir. Eğitim aşamasında oluşturulan karar verme algoritmasının performansı test verileri kullanılarak incelenir. Bu süreç yani sınıflandırma aşaması Şekil 4,2’de verilmiştir.




Tablo 4.2. Orta Seviye Karar Ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	92,5	0,74	0,99	91,2
Meyer	93,0	0,89	0,98	92,5
db2	95,2	1,00	0,97	95,0
db4	94,7	0,97	0,98	93,8
db6	95,7	0,95	1,00	95,0

Orta Seviye Karar Ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.2’de verilmiştir. Orta seviye karar ağacı elde edilen en iyi performans değerinin db6 dalgacı ile alınmış olduğu görülmektedir. db6 dalgacı ile yapılan analizde eğitim doğruluğu % 95,7 ve test doğruluğu % 95,0 olarak bulunmuştur.

4.3. Kompleks Karar Ağacı

Kompleks karar ağacı (Complex Tree) için model esnekliği yüksektir. Çok sayıda yaprak içerir. Kompleks karar ağacı yapımız için maksimum bölünme sayısı değeri 100 olarak seçilmiştir. Bu değer kompleks ağaçlar için büyük bir değer olarak seçilmelidir. Denemeler sonunda 100 değerini modelimiz için en uygun değer olduğuna karar verildi. Gini'nin çeşitlilik endeksi, bölünme kriteri olarak seçilmiştir. MATLAB kullanılarak hazırlanmış bir karar ağacı Şekil 4,3'de verilmiştir.



Şekil 4.3. MATLAB kullanılarak hazırlanmış bir karar ağacı

Tablo 4.3. Kompleks karar ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

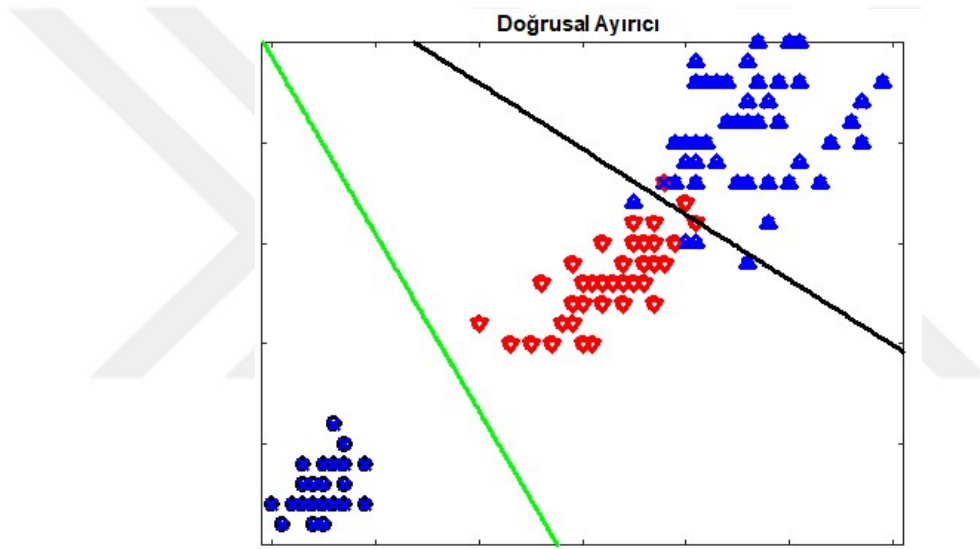
Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	96,1	0,96	1,00	95,0
Meyer	95,9	1,00	0,99	94,4
db2	95,3	1,00	0,98	95,0
db4	94,9	0,97	0,98	94,4
db6	95,0	0,89	1,00	94,7

Kompleks karar ağacı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.3'de verilmiştir. Kompleks karar ağacı elde edilen en iyi performans değerinin Haar dalgacığı ile alınmış olduğu

görülmektedir. Haar dalgacığı ile yapılan analizde eğitim doğruluğu % 95,0 ve test doğruluğu % 94,7 olarak bulunmuştur.

4.4. Doğrusal Ayırıcı

Doğrusal Ayırıcı (Linear Discriminant) sınıflandırmasında daha önce iki veya daha fazla grup bilinmektedir ve yeni gözlemler ile ölçülen özelliklere dayalı olarak bilinen gruplara ayrılmaktadır. MATLAB kullanılarak hazırlanmış bir doğrusal ayırıcı sınıflandırması Şekil 4.4’de verilmiştir.



Şekil 4.4. MATLAB kullanılarak hazırlanmış doğrusal ayırıcı sınıflandırması

Tablo 4.4. Doğrusal ayırıcı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	78,3	0,40	0,94	77,5
Meyer	74,3	0,21	0,94	73,8
db2	76,9	0,29	0,96	76,3
db4	79,2	0,38	0,98	78,9
db6	85,1	0,46	0,99	84,4


Doğrusal ayırıcı kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.4’de verilmiştir. Doğrusal ayırıcı elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduğu görülmektedir ve db6 dalgacığı ile yapılan analizde eğitim doğruluğu % 85,1 ve test doğruluğu % 84,4 olarak bulunmuştur.

4.5. Hassas K En Yakın Komşu Sınıflandırması

K- en yakın komşu sınıflandırma yöntemlerinin kullanılmasının en önemli nedeni, mesafe temelli sınıflandırmanın etkili ve aynı zamanda basit bir yöntem olmasıdır. KNN algoritması, en küçük mesafeli noktaları bularak ve bu noktaların ait olduğu sınıf bilgilerini kullanarak yeni noktanın sınıfını tanımlayan bir yöntemdir. Noktalara olan uzaklığı bulmak için farklı yöntemler vardır. Öklid uzaklığı mesafe ölçüm yöntemi olarak seçilmiştir. İki nokta x_i ve y_i arasındaki öklid uzaklığı denklem 4.4 kullanılarak bulunur. MATLAB kullanılarak hazırlanmış 1 en yakın komşu sınıflandırması Şekil 4.5’de verilmiştir.

$$ÖU = \sqrt{\sum(x_i - y_i)^2} \quad (4.4)$$

ÖU= Öklid uzaklığı, x_i = x konum bilgisi, y_i = y konum bilgisi,



Şekil 4.5. MATLAB kullanılarak hazırlanmış 1 en yakın komşu sınıflandırması

Sınıflandırırken, hassas veya kaba sınıflandırıcıyı belirleyen komşu sayısını belirtmeliyiz. Hassas K en yakın komşu sınıflandırma (Fine KNN) yöntemi için komşuların sayısını 1 olarak ayarladık. Birçok komşunun kullanılmasının zaman alıcı olduğu dikkate alınmalıdır. Ve artan sayıda komşu model esnekliğini azaltır. Hassas K en yakın komşu sınıflandırmada model esnekliğimizin fazla olmasını istiyoruz.

Ağırlıklandırma fonksiyonu olarak ters (ağırlık = 1 / mesafe), kare ters (ağırlık=1/ mesafe²) veya eşit (ağırlıksız), mesafe seçilebilir. Hassas K en yakın komşu sınıflandırma yöntemi için eşit ağırlıklandırma işlevi basitlik için seçilmiştir.

Her koordinat mesafesinin ölçeklendirilmesi karar verilecek başka bir niteliktir. Araştırmamız için verileri standartlaştırmayı tercih ettik.

Hassas K en yakın komşu sınıflandırma yöntemi için tahmin etme hızı orta seviyededir. Bellek kullanımı orta düzeydedir. Yorumlama kabiliyeti kullanımı zordur. Sınıflar arasındaki ince detaylı ayrımlar tanımlanmıştır.

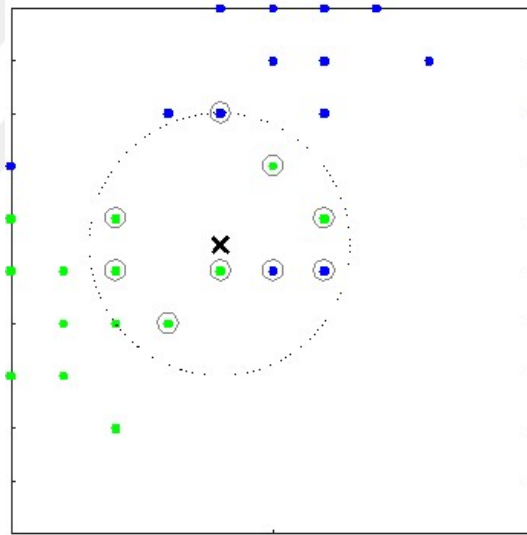
Tablo 4.5. Hassas K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	97,1	0,97	1,00	96,4
Meyer	96,8	0,95	1,00	95,9
db2	97,1	0,97	1,00	96,8
db4	97,9	0,98	1,00	97,0
db6	97,1	0,89	1,00	95,9

Hassas K en yakın komşu sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.5’de verilmiştir. Hassas K en yakın komşu sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db4 dalgacığı ile alınmış olduğu görülmektedir. db4 dalgacığı ile yapılan analizde eğitim doğruluğu % 97,9 ve test doğruluğu % 97,0 olarak bulunmuştur.

4.6. Orta Derece K En Yakın Komşu Sınıflandırması

Orta derece K en yakın komşu (Medium KNN) sınıflandırması yöntemi hassas K en yakın komşu sınıflandırmasına göre daha az ayırım yapan en yakın komşu sınıflandırıcısıdır. Bu sınıflandırma yöntemi için komşuların sayısını 10 olarak ayarladık. Bu sınıflandırmada 10 seçilmesi model esnekliğini azaltmış ve hesaplamayı zorlaştırmıştır. Ama karar verme için daha çok komşudan yararlanılması modelin kararlılığını artırmıştır. MATLAB kullanılarak hazırlanmış 10 en yakın komşu sınıflandırmasına ait bir örnek durum Şekil 4.6'da verilmiştir. Eşit ağırlıklandırma işlevi tercih edilmiştir. Tahmin etme hızı orta seviyededir. Bellek kullanımı orta düzeydedir. Yorumlanabilirlik seviyesi zordur. Sınıflar arasında orta derecede ayrımlar tanımlanmıştır.



Şekil 4.6. MATLAB kullanılarak hazırlanmış 10 en yakın komşu sınıflandırması

Tablo 4.6. Orta Derece K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	92,9	0,86	0,99	91,9
Meyer	90,8	0,73	0,99	90,7
db2	92,1	0,83	0,98	91,3
db4	92,8	0,80	0,99	91,3
db6	93,2	0,89	0,99	92,5

Orta derece K en yakın komşu sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.6’da verilmiştir. Orta derece K en yakın komşu sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduğu görülmektedir db6 dalgacığı ile yapılan analizde eğitim doğruluğu % 93,2 ve test doğruluğu % 92,5 olarak bulunmuştur.

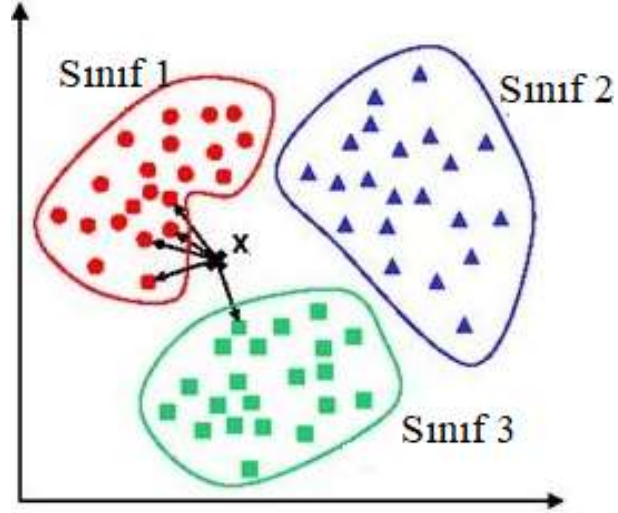
4.7. Yüzeysel K En Yakın Komşu Sınıflandırması

Yüzeysel K en yakın komşu sınıflandırması (Coarse KNN) yöntemi için komşuların sayısını 100 olarak ayarladık. Bu sınıflandırmada 100 seçilmesi model esnekliğini daha da azaltmış ve hesaplamayı çok zorlaştırmıştır. Ama karar verme için daha çok komşudan yararlanılması modelin kararlılığını daha da artırmış ve sınıflar arasındaki yüzeysel ayrımlar tanımlanmıştır. Eşit ağırlıklandırma işlevi tercih edilmiştir. Tahmin etme hızı orta seviyededir. Bellek kullanımı orta düzeydedir. Yorumlanabilirlik seviyesi zordur.

Tablo 4.7. Yüzeysel K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	75,0	0,20	1,00	75,0
Meyer	75,7	0,21	1,00	75,1
db2	75,0	0,20	1,00	75,0
db4	75,4	0,20	1,00	75,0
db6	75,3	0,20	1,00	75,0

Yüzeysel K en yakın komşu sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.7’de verilmiştir. Yüzeysel K en yakın komşu sınıflandırma yöntemiyle elde edilen en iyi performans değerinin Meyer dalgacığı ile alınmış olduğu görülmektedir. Meyer dalgacığı ile yapılan analizde eğitim doğruluğu % 75,7 ve test doğruluğu % 75,1 olarak bulunmuştur. K En Yakın Komşu Sınıflandırmasına ait bir örnek Şekil 4.7’de verilmiştir.



Şekil 4.7. K En Yakın Komşu Sınıflandırmasına ait bir örnek

4.8. Kosinüs K En Yakın Komşu Sınıflandırması

Kosinüs K en yakın komşu sınıflandırma (Cosine KNN) yöntemi için komşuların sayısını 10 olarak ayarladık. Bu sınıflandırmada 10 seçilmesiyle modelin kararlılığını artırmıştır. Eşit ağırlıklandırma işlevi tercih edilmiştir. Tahmin etme hızı orta seviyededir. Bellek kullanımı orta düzeydedir. Yorumlanabilirlik seviyesi zordur. Kosinüs uzaklık metriğini kullanarak sınıflar arasında orta derecede ayrımlar tanımlanmıştır. Kosinüs uzaklık metriğini hesaplamada denklem 4.5'den yararlanabiliriz.


$$Kd = 1 - \frac{x \cdot y'}{\sqrt{(x \cdot x') \cdot (y \cdot y')}} \quad (4.5)$$

Kd = Kosinüs uzaklık, $x = x$ konum vektörü, $y = y$ konum vektörü,

Tablo 4.8. Kosinüs K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	90,4	0,75	1,00	90,2
Meyer	88,9	0,70	0,98	88,2
db2	90,2	0,70	0,99	90,0
db4	89,8	0,75	0,98	88,8
db6	87,1	0,75	0,96	86,9

Kosinüs K en yakın komşu sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.8’de verilmiştir. Kosinüs K en yakın komşu sınıflandırma yöntemiyle elde edilen en iyi performans değerinin Haar dalgacığı ile alınmış olduğu görülmektedir. Haar dalgacığı ile yapılan analizde eğitim doğruluğu % 90,4 ve test doğruluğu % 90,2 olarak bulunmuştur. İki nokta arasında d mesafesi veya θ açısı belirleyici olarak kullanılabilir. İki nokta arasında d mesafesi ve θ açısının görsel şekilde Şekil 4.8’de verilmiştir.



Şekil 4.8. İki nokta arasında d mesafesi ve θ açısının görsel gösterimi

4.9. Kübik K En Yakın Komşu Sınıflandırması

Kübik K en yakın komşu sınıflandırma (Cubic KNN) yöntemi için komşuların sayısını 10 olarak ayarladık. Bu sınıflandırmada 10 seçilmesiyle modelin kararlılığını artırmıştır. Bu sınıflandırmada 10 seçilmesiyle modelin kararlılığını artırmıştır. Eşit ağırlıklandırma işlevi tercih edilmiştir. Tahmin etme hızı yavaştır. Bellek kullanımı orta düzeydedir. Yorumlanabilirlik seviyesi zordur. Kübik uzaklık hesaplama metodu kullanarak sınıflar arasında orta derecede ayrımlar tanımlanmıştır.

Tablo 4.9. Kübik K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	92,7	0,83	0,99	91,9
Meyer	90,8	0,73	0,99	90,6
db2	91,5	0,83	0,98	91,3
db4	91,5	0,81	0,99	91,1
db6	92,3	0,83	0,99	91,8

Kübik K en yakın komşu sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.9'da verilmiştir. Kübik K en yakın komşu sınıflandırma yöntemiyle elde edilen en iyi performans değerinin Haar dalgacığı ile alınmış olduğu görülmektedir. Haar dalgacığı ile yapılan analizde eğitim doğruluğu % 92,7 ve test doğruluğu % 91,9 olarak bulunmuştur.

4.10. Ağırlıklı K En Yakın Komşu Sınıflandırması

Ağırlıklı K en yakın komşu sınıflandırması (Weighted KNN) yöntemi için denemeler sonunda komşuların sayısını 10 olarak seçtik. Bu şekilde sınıflar arası ayrımlar daha belirginleşmiştir. Eşit ağırlıklandırma işlevi tercih edilmiştir. Tahmin etme hızı orta seviyededir. Bellek kullanımı orta düzeydedir. Yorumlanabilirlik seviyesi zordur. Ağırlıklı uzaklık hesaplama metodu kullanarak sınıflar arasında orta derecede ayrımlar tanımlanmıştır.

Tablo 4.10. Ağırlıklı K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	96,2	0,89	1,00	95,0
Meyer	95,8	0,89	1,00	95,0
db2	96,3	0,90	1,00	95,1
db4	95,7	0,89	1,00	95,0
db6	96,1	0,89	1,00	95,1

Ağırlıklı K en yakın komşu sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.10'da verilmiştir. Ağırlıklı K en yakın komşu sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db2 dalgacığı ile alınmış olduğu görülmektedir. db2 dalgacığı ile yapılan analizde eğitim doğruluğu % 96,3 ve test doğruluğu % 95,1 olarak bulunmuştur.

4.11. Geliştirilmiş Ağaç

Geliştirilmiş ağaç (Boosted trees) sınıflandırma yöntemi için, için grup yöntemi Adaptive Boosting (AdaBoost) seçilmiştir. Bu yöntem çok miktarda zayıf öğreniciyi bir araya getirip, bu süreçten güçlü öğrenici oluşturmak olarak bilinir. AdaBoost algoritması bu alandaki ilk yararlı algoritma olduğu söylenebilir. AdaBoost, çok sayıda özellik içeren sınıflamalar için özellikle yararlıdır. AdaBoost eğitim süreci, boyut performansını düşürür ve modelin performansını artırdığı bilinen özellikleri seçerek yürütme süresini geliştirir. Uygulanabilir olması, az hafıza kullanması, tahmin hızının daha yüksek olmasından dolayı tercih edilmektedir.

Öğrenme tipi karar ağacıdır. Karar ağaçları, hızlı sınıflandırma için en iyi seçeneklerden biridir ve ayrıca yorumlanması kolaydır. Maksimum bölünme sayısı derinliği kontrol etmemizi sağlar. Büyük değerlerde işlemci üzerindeki yük ve hesaplama süresi artar. Model daha karmaşık olur. Denemeler sonucunda bu sınıflandırıcı için maksimum bölünme sayısı 20 olarak seçilmiştir. Model esnekliği, öğrenen sayısı ayarı ile artar. Ancak öğrenen sayısı arttıkça modelin sınıflandırma için kullandığı zaman artar. Öğrenen sayısını değiştirerek performanstaki artış ve sınıflandırma süresindeki değişime bakarak uygun bir öğrenme değeri belirlendi. Bu sınıflandırıcı için öğrenen sayısı 30 olarak belirlendi. Öğrenme oranı düşük olursa daha az öğrenen sayısına ihtiyaç duyar. Küçük bir sayı seçerek daha iyi sınıflandırma yapmamız mümkün olabilir ancak sınıflandırma için ihtiyaç duyulan süre ve öğrenen sayısı artar. Denemeler sonucunda bu sınıflandırıcı için öğrenme oranı 0,1 olarak belirlendi.

Tablo 4.11. Geliştirilmiş Ağaç Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	96,4	1,00	0,99	95,0
Meyer	95,4	0,89	1,00	95,0
db2	96,5	1,00	0,99	95,1
db4	95,8	0,89	1,00	95,0
db6	95,5	0,90	1,00	95,0

Geliştirilmiş ağaç sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.11’de verilmiştir. Geliştirilmiş ağaç sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db2 dalgacığı ile alınmış olduğu görülmektedir ve db2 dalgacığı ile yapılan analizde eğitim doğruluğu % 96,5 ve test doğruluğu % 95,1 olarak bulunmuştur.

4.12. Torbalama Karar Ağaçları

Torbalama karar ağaçları (Bagged Trees) için grup yöntemi torbalama olarak seçildi. Torbalama genellikle derin ağaçlar oluşturur. Bu yapı hem zaman alıcıdır hem de yoğun bellek kullanımı gerektirir. Bu da nispeten yavaş tahminlere yol açar. Torbalama yönteminde çapraz doğrulama yapılmadan genelleme hatası tahmin edilebilir. Öğrenme tipi karar ağacıdır. Karar ağaçları, hızlı sınıflandırma için en iyi seçeneklerden biridir ve ayrıca yorumlanması kolaydır. Öğrenen sayısını ve maksimum bölünme sayısını artırmak sınıflandırma performansını artırabilir ancak hesaplama süresindeki artış hızlı karar vermeyi mümkün kılmaz. Denemeler sonunda öğrenen sayısı 30 ve maksimum bölünme sayısı 20 olarak belirledik.

Tablo 4.12. Torbalama Karar Ağaçları Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	95,6	0,91	1,00	95,0
Meyer	95,4	0,91	1,00	95,0
db2	95,5	1,00	0,98	95,0
db4	95,5	0,95	0,99	95,0
db6	95,9	1,00	0,99	95,1

Torbalama karar ağaçları sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.12’de verilmiştir. Torbalama karar ağaçları sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduğu görülmektedir ve db6 dalgacığı ile yapılan analizde eğitim doğruluğu % 95,9 ve test doğruluğu % 95,1 olarak bulunmuştur.

4.13. Altuzay Ayırımı

Altuzay ayırımı (Subspace Discriminant) Sınıflandırma yöntemi için grup yöntemi altuzay olarak seçildi. Öğrenme tipi olarak diskriminant analizi tercih edildi. Öğrenen sayısındaki artış sınıflandırma performansında bir artış oluşturabilir ancak sınıflandırma süresinde artıracaktır. Altuzay boyutu rastgele her öğrenene dâhil edilecek öngörücü sayısını belirtir. Denemeler sonunda bizim sınıflandırma yöntemimiz için en uygun değerler öğrenen sayısı 30, altuzay boyutu 2 olarak tespit edilmiştir.

Tablo 4.13. Altuzay Ayırımı Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	75,9	0,27	0,97	75,6
Meyer	73,8	0,18	0,98	73,8
db2	76,9	0,17	0,97	76,3
db4	75,6	0,19	0,98	75,0
db6	82,2	0,49	0,94	81,9

Altuzay ayırımı sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.13’de verilmiştir. Altuzay ayırımı sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduğu görülmektedir ve db6 dalgacığı ile yapılan analizde eğitim doğruluğu % 82,2 ve test doğruluğu % 81,9 olarak bulunmuştur.

4.14. Altuzay K En Yakın Komşu Sınıflandırması

Altuzay K en yakın komşu (Subspace KNN) sınıflandırması grup yöntemi altuzay olarak seçildi. Öğrenme tipi olarak en yakın komşu algoritması tercih edildi. Koşullara bakarak bizim sınıflandırma yöntemimiz için en uygun değerler öğrenen sayısı 30, altuzay boyutu 2 olarak tespit edilmiştir.

Tablo 4.14. Altuzay K En Yakın Komşu Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	95,6	0,89	1,00	95,1
Meyer	95,7	0,90	1,00	95,2
db2	95,5	0,89	1,00	95,0
db4	95,4	0,89	1,00	95,0
db6	95,6	0,89	1,00	95,0

Altuzay K en yakın komşu sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.14’de verilmiştir. Altuzay K en yakın komşu sınıflandırma yöntemiyle elde edilen en iyi performans değerinin Meyer dalgacığı ile alınmış olduğu görülmektedir. Meyer dalgacığı ile yapılan analizde eğitim doğruluğu % 95,7 ve test doğruluğu % 95,2 olarak bulunmuştur.

4.15. RUS Geliştirilmiş Ağaç

RUS geliştirilmiş ağaç (RUS Boosted trees) Sınıflandırması grup yöntemi RUSBoost olarak seçildi. RUSBoost, SMOTEBoost algoritmasına dayanıyor. SMOTEBoost, akıllı bir aşırı örnekleme tekniğı kullanımı ile AdaBoost'u geliştirmiştir. RUSBoost daha hızlı model eğitim süreleri ve olumlu performans ile daha basit bir algoritmadır. Öğrenme tipi karar ağacıdır. Denemeler sonucunda öğrenen sayısı 30, öğrenme oranı 0,1, maksimum bölünme sayısı 20 olarak seçilmiştir.

Tablo 4.15. RUS Geliştirilmiş Ağaç Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	84,0	0,89	0,87	83,2
Meyer	87,1	0,89	0,89	85,7
db2	81,4	0,89	0,82	80,7
db4	84,4	0,89	0,87	84,3
db6	85,4	0,89	0,87	85,0

RUS geliştirilmiş ağaç Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.15’de verilmiştir. RUS geliştirilmiş ağaç Sınıflandırma yöntemiyle elde edilen en iyi performans değerinin Meyer dalgacığı ile alınmış olduğu görülmektedir. Meyer dalgacığı ile yapılan analizde eğitim doğruluğu % 87,1 ve test doğruluğu % 85,7 olarak bulunmuştur.

4.16. Doğrusal Destek Vektör Makinesi

Destek vektör makinesi (support vector machine, SVM), verileri ayırmak için en iyi hiperdüzeyi (sınıflar arasında en büyük farkı içeren) bulur. SVM, aykırı noktalara karşı dayanıklıdır.

Doğrusal destek vektör makinesi (Linear SVM) sınıflandırması için tahmin etme hızı orta seviyededir. Hafıza kullanımı orta seviyededir. Yorumlanabilirlik seviyesi kolaydır. Model esnekliği düşüktür. Kutu sınırlama seviyesini belirterek, Lagrange çarpanlarının değerlerini sınırlı bir bölgede tutabiliriz. Kutu sınırlama düzeyi 1 olarak seçildi. Arttırılması eğitim süresini artırabilir, ancak destek vektörlerinin sayısını da azaltabilir. Çekirdek ölçeği otomatik olarak seçildi. Ölçek değerini seçmek için sezgisel bir prosedür kullanılmaktadır.

Tablo 4.16. Doğrusal Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	77,4	0,34	0,98	76,9
Meyer	77,2	0,29	0,98	76,3
db2	77,6	0,31	0,97	76,9
db4	81,5	0,33	0,98	80,6
db6	81,7	0,34	0,97	81,3

Doğrusal destek vektör makinesi sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.16’da verilmiştir. Doğrusal destek vektör makinesi sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduğu görülmektedir

ve db6 dalgacıđı ile yapılan analizde eğitim dođruluđu % 81,7 ve test dođruluđu % 81,3 olarak bulunmuştur.

4.17. Kuadratik Destek Vektör Makinesi

SVM'de, bu iki sınıf arasında doğrusal bir hiper düzlemin bulunması kolaydır. Diğer durumlar için SVM, çekirdek (kernel) diye bir teknik kullanıyor. Bunlar, düşük boyutlu girdi alanını alır ve daha yüksek boyutlu bir boşluđa dönüştüren işlevlerdir. Doğrusal olmayan ayırma probleminde çođunlukla yararlıdır.

Kuadratik destek vektör makinesi (Quadratic SVM) sınıflandırması için tahmin etme hızı yavaştır. Hafıza kullanımı fazladır. Yorumlanabilirlik seviyesi zordur. Model esnekliđi orta seviyededir. Kutu sınırlama düzeyi 1 olarak seçildi. Çekirdek ölçeđi otomatik olarak seçildi.

Tablo 4.17. Kuadratik Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada deđişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eđitim Dođruluđu	Hassaslık	Özgünlük	Test Dođruluđu
Haar	86,0	0,58	0,97	85,6
Meyer	84,4	0,45	0,95	83,2
db2	85,9	0,43	0,98	85,7
db4	88,8	0,66	0,99	88,2
db6	88,5	0,58	0,98	88,1

Kuadratik destek vektör makinesi sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada deđişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.17'de verilmiştir. Kuadratik destek vektör makinesi sınıflandırma yöntemiyle elde edilen en iyi performans deđerinin db4 dalgacıđı ile alınmış olduđu görülmektedir. db4 dalgacıđı ile yapılan analizde eğitim dođruluđu % 88,8 ve test dođruluđu % 88,2 olarak bulunmuştur.

4.18. Kübik Destek Vektör Makinesi

Kübik destek vektör makinesi (Cubic SVM) sınıflandırması için tahmin etme hızı yavaştır. Hafıza kullanımı fazladır. Yorumlanabilirlik seviyesi zordur. Model esnekliği orta seviyededir. Kutu sınırlama düzeyi 1 olarak seçildi. Çekirdek ölçeği otomatik olarak seçildi.

Tablo 4.18. Kübik Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	87,4	0,58	0,98	86,9
Meyer	60,3	0,47	0,65	58,2
db2	28,5	0,60	0,21	27,5
db4	42,7	0,69	0,26	33,2
db6	50,4	0,68	0,49	49,4

Kübik destek vektör makinesi sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.18’de verilmiştir. Kübik destek vektör makinesi sınıflandırma yöntemiyle elde edilen en iyi performans değerinin Haar dalgacığı ile alınmış olduğu görülmektedir. Haar dalgacığı ile yapılan analizde eğitim doğruluğu % 87,4 ve test doğruluğu % 86,9 olarak bulunmuştur.

4.19. Hassas Gauss Destek Vektör Makinesi

Hassas gauss destek vektör makinesi (Fine gaussian SVM) sınıflandırması için tahmin etme hızı yavaştır. Hafıza kullanımı fazladır. Yorumlanabilirlik seviyesi zordur. Model esnekliği yüksek seviyededir. Çekirdek ölçeği $\sqrt{P}/4$ olarak belirlenmiş sınıflar arasında ince ayrıntılı ayrımı yapar. P tahmin edicilerin sayısıdır. Kutu sınırlama düzeyi 1 olarak seçildi. Çekirdek ölçeği gauss olarak seçildi.

Tablo 4.19. Hassas Gauss Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	87,8	0,44	0,99	86,9
Meyer	79,4	0,23	0,97	80,0
db2	85,3	0,29	1,00	84,4
db4	86,5	0,37	1,00	86,3
db6	89,3	0,55	0,99	88,8

Hassas gauss destek vektör makinesi sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.19’de verilmiştir. Hassas gauss destek vektör makinesi sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduğu görülmektedir ve db6 dalgacığı ile yapılan analizde eğitim doğruluğu % 89,3 ve test doğruluğu % 88,8 olarak bulunmuştur.

4.20. Orta Derece Gauss Destek Vektör Makinesi

Orta derece gauss destek vektör makinesi (Medium gaussian SVM) sınıflandırması için tahmin etme hızı yavaştır. Hafıza kullanımı fazladır. Yorumlanabilirlik seviyesi zordur. Model esnekliği orta seviyededir. Çekirdek ölçeği \sqrt{P} olarak belirlenmiş sınıflar arasında orta seviyede ayırım yapar. Kutu sınırlama düzeyi 1 olarak seçildi. Çekirdek ölçeği gauss olarak seçildi.

Tablo 4.20. Orta Derece Gauss Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	83,3	0,35	0,98	81,9
Meyer	75,9	0,22	1,00	75,7
db2	82,3	0,23	0,98	81,3
db4	79,7	0,22	1,00	78,8
db6	86,6	0,37	1,00	85,7

Orta derece gauss destek vektör makinesi sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada değişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.20’de verilmiştir. Orta derece gauss destek vektör makinesi sınıflandırma

yöntemiyle elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduđu görölmektedir ve db6 dalgacığı ile yapılan analizde eğitim doğruluđu % 86,6 ve test doğruluđu % 85,7 olarak bulunmuştur.

4.21. Yüzeysel Gauss Destek Vektör Makinesi

Yüzeysel gauss destek vektör makinesi (Coarse gaussian SVM) sınıflandırması için tahmin etme hızı yavaştır. Hafıza kullanımı fazladır. Yorumlanabilirlik seviyesi zordur. Model esnekliđi düşük seviyededir. Çekirdek ölçeđi $\sqrt{P} * 4$ olarak belirlenmiş sınıflar arasında yüzeysel seviyede ayırım yapar. Kutu sınırlama düzeyi 1 olarak seçildi. Çekirdek ölçeđi gauss olarak seçildi.

Tablo 4.21. Yüzeysel Gauss Destek Vektör Makinesi Sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada deđişik dalgacık kullanımlarından elde edilen performans sonuçları.


Dalgacık	Eđitim Doğruluđu	Hassaslık	Özgünlük	Test Doğruluđu
Haar	76,0	0,21	1,00	75,7
Meyer	75,4	0,20	1,00	75,0
db2	75,2	0,20	1,00	75,0
db4	75,2	0,20	1,00	75,0
db6	80,6	0,24	1,00	80,0

Yüzeysel gauss destek vektör makinesi sınıflandırma yöntemi kullanılarak yapılan sınıflandırmada deđişik dalgacık kullanımlarından elde edilen performans sonuçları Tablo 4.21'de verilmiştir. Yüzeysel gauss destek vektör makinesi sınıflandırma yöntemiyle elde edilen en iyi performans değerinin db6 dalgacığı ile alınmış olduđu görölmektedir. db6 dalgacığı ile yapılan analizde eğitim doğruluđu % 80,6 ve test doğruluđu % 80,0 olarak bulunmuştur.

BÖLÜM 5. SİSTEM MODELLEMESİ

Güç sistemlerindeki bozulmalar planlanmamış veya planlanmış nedenlerden dolayı meydana gelir ve özellikle elektronik cihazların çalışmasını olumsuz etkiler. Bu bozulmalar dalga şeklindeki bozulmalar şeklindedir.

Güç kalitesindeki bozulmanın analiz edilmesi, bozulma işaretlerinin doğru modellenmesi ile mümkün olabilir. Bu tezde, incelenecek olan güç kalitesi bozulma işaretleri MATLAB ortamında matematiksel denklemlerinden yararlanılarak üretilmiştir. Oluşturulan bu güç kalitesi bozulma işaretlerini içeren 900 tane 1,2 saniyelik sinyal oluşturulmuştur. Örnek bir sinyal Şekil 5.1’de verilmiştir. Bu veri tabanında dokuz farklı sınıf bulunmaktadır. Bu sınıflar Tablo 5.1’de verilmiştir.




Şekil 5.1. MATLAB ortamında oluşturulmuş örnek bir sinyal.

Bu çalışmada sadece güç kalitesindeki bozulmayı tespit etmek değil, ayrıca güç kalitesindeki bozulma çeşidini de belirlenmiştir. Bu veri tabanı harmanlanarak yarısı eğitim ve yarısı test sürecinde kullanılmıştır.

Tablo 5.1. Veri tabanında belirlenen dokuz farklı sınıf.

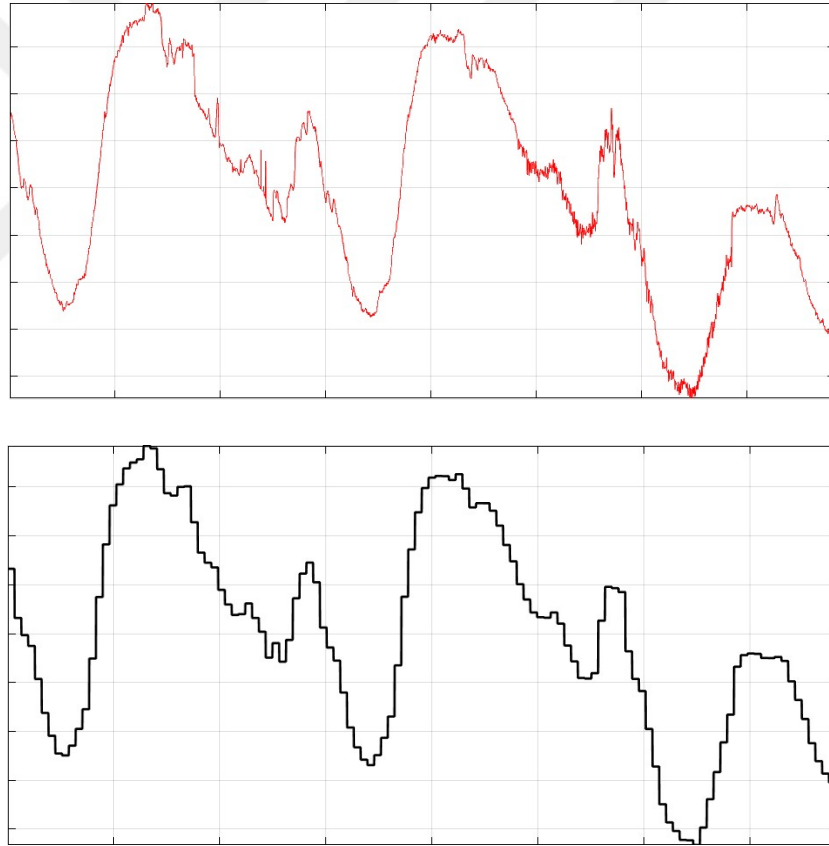
Sınıf 1	Normal 50 Hz Sinüs Dalgası
Sınıf 2	Harmonikler
Sınıf 3	Gerilim Çökmesi
Sınıf 4	Gerilim Yükselmesi
Sınıf 5	Gerilim Kesintisi
Sınıf 6	Gerilim Dalgalanmaları
Sınıf 7	Gerilim Titremesi
Sınıf 8	Gerilim Çökmesine ek olarak Harmonikler
Sınıf 9	Gerilim Yükselmesine ek olarak Harmonikler

Güç kalitesi bozulma işaretlerini içeren sinyaller ayrık 8. Seviye dalgacık dönüşümü sayesinde ayrıntı ve yaklaşım katsayılarına ayrıştırılır. Bozulma işaretlerini içeren bir sinyalin 8. Seviye Haar dalgacık dönüşümü, ayrıntı katsayıları ve yaklaşık katsayıları Şekil 5.2 üzerinde görülebilir. Bu tezde değişik dalgacıklar test edilmiş ve güç kalitesi bozulma işaretlerini tespit etmek için en uygun dalgacık tespit edilmiştir. Sinyaller 12. Seviyeye kadar ayrıştırmamız mümkün ancak 50Hz'in altını inceleyen ayrıştırmalar güç kalitesi analizimiz için önemli bulunmadığından, sekizinci ayrıştırma seviyesinde ayrıştırma yapılmıştır. Dalgacık analizinde MATLAB fonksiyonları ve wavelet toolbox kullanıldı.



Şekil 5.2. Bozulma işaretlerini içeren sinyalin 8. Seviye Haar dalgacık dönüşümü.

Bu çalışmada test edilen dalgacıklar sırasıyla Haar, Daubechies (db2, db4, db6), Meyer şeklindedir. Benzer çalışmaları incelediğimizde yalnızca bir çeşit dalgacık kullanıldığı görülmektedir. Değişik dalgacık çeşitlerinin karşılaştırılmalı olarak kullanıldığı bir çalışmaya rastlanmamıştır. Çalışmamızda kullanılan Haar dalgacık fonksiyonu en basit yapıdaki dalgacık fonksiyonudur. Haar dalgacık, tüm dikey dalgacıklar arasında en küçük desteğe sahiptir. Kullandığımız diğer dalgacık çeşidi olan Daubechies dalgacıkları verilen destek için maksimum sayıda sıfırlanan moment ile karakterize edilen dikey dalgacık aileleridir. Pek çok alanda başarıyla kullanıldığı çalışmaları bulunmaktadır. Son olarak kullandığımız Meyer dalgacığı düzgün bir Fourier dönüşümü olan frekans bandıyla sınırlı bir fonksiyondur. Özellikle güç sistemlerinin incelendiği çalışmalarda kullanılmaktadır. Bozulma işaretlerini içeren bir sinyal, onun tekrar oluşturulmuş hali Şekil 5.3’de verilmiştir.



Şekil 5.3. Bozulma işaretlerini içeren bir sinyal, onun tekrar oluşturulmuş hali

Daha fazla veri çoğunlukla daha iyi sınıflandırma anlamına gelir. Ancak bu çalışmada daha hızlı sınıflandırma için özellik sayısını azaltmaya karar verdik. Bilginin çoğunu koruyan değişkenlerin türetilmesi ve seçilen özelliklerin azaltılması için Temel

bileşenler analizi (Principal Component Analysis, PCA) yönteminin kullanılması tercih edilmiştir. Bunu ana bileşenlere, yani birbiriyle ilişkili olmayan yeni bir değişkenler grubuna dönüştürerek elde edilir ve varyasyonların çoğu ilk birkaç değişkende saklanır [54].

Temel bileşenler analizi için temel adımlar

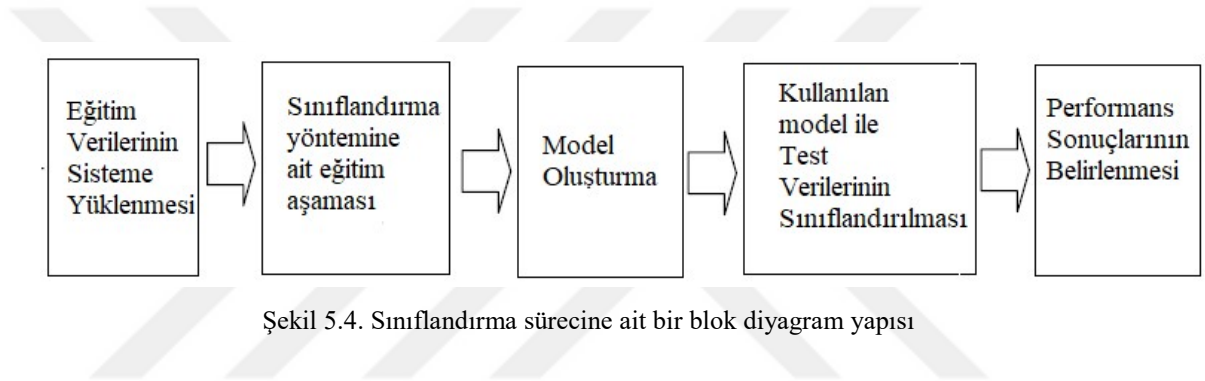
1. Veri hazırlanır. Sinyalin ortalaması hesaplanır.
2. Ortalama değer original sinyal değerlerinden çıkarılır. Böylece ortalaması sıfır olan bir veri kümesi elde edilir.
3. Kovaryans / korelasyon matrisini hesaplanır.
4. Özdeğerleri ve özvektörleri hesaplanır.
5. Özdeğerler ve karşılık gelen özvektörler büyükten küçüğe doğru düzenlenir.
6. Ana bileşenleri seçilir. Yeni veri kümesini hesaplanır.

Temel bileşenler Analizi, gerçek özvektör tabanlı çok değişkenli analizlerin en basitidir. Çoğu zaman, çalışmasının verilerin iç yapısını, verideki varyansı en iyi açıklayan şekilde ortaya koyduğu düşünülür. Çok değişkenli bir veri kümesinin, yüksek boyutlu bir veri alanındaki bir koordinat kümesi olarak görselleştirildiğini düşünelim. Temel bileşenler Analizi, bu durumda kullanıcıya en bilgilendirici bakış açısından bakıldığında, nesnenin bir alt boyutlu resimini sunabilir. PCA faktör analizi ile yakından ilişkilidir. Faktör analizi tipik olarak, altta yatan yapıyla ilgili daha alana özgü varsayımları içerir ve farklı bir matrisin özvektörlerini çözer. PCA, kanonik korelasyon analizi (Canonical Correlation Analysis, CCA) ile de ilgilidir. CCA, iki veri kümesi arasındaki çapraz kovaryansı en iyi tanımlayan koordinat sistemlerini tanımlarken, PCA tek bir veri kümesindeki varyansı optimum olarak tanımlayan yeni bir ortogonal koordinat sistemi tanımlar [55].

Sınıflandırma aşamasında değişik sınıflandırma yöntemleri incelenmiştir. Güç kalitesindeki bozulma çeşidini tespit için en uygun dalgacığı belirlemeye ek olarak en uygun sınıflandırma yöntemini belirlemek bu tezin amaçları arasındadır. Güç kalitesindeki bozulmanı tespitinde değişik sınıflandırma yöntemlerinin karşılaştırıldığı bir çalışmaya rastlanılmamıştır. Bu tezde kullanılan sınıflandırma yöntemleri aşağıda verilmiştir: Basit Karar Ağacı, Orta Seviye Karar Ağacı, Kompleks Karar

Ağacı, Hassas K En Yakın Komşu, Orta Derece K En Yakın Komşu, Yüzeysel K En Yakın Komşu, Kosinüs K En Yakın Komşu, Kübik K En Yakın Komşu, Ağırlıklı K En Yakın Komşu, Doğrusal Ayırıcı, Geliştirilmiş Ağaç, Torbalama Karar Ağaçları, Altuzay Ayırımı, Altuzay KNN, RUS Geliştirilmiş Ağaç, Doğrusal Destek Vektör Makinesi, Kuadratik Destek Vektör Makinesi, Kübik Destek Vektör Makinesi, Hassas Gauss Destek Vektör Makinesi, Orta Derece Gauss Destek Vektör Makinesi, Yüzeysel Gauss Destek Vektör Makinesi

Toplamda 21 çeşit sınıflandırma yöntemi incelenmiştir. Sınıflandırma sürecine ait bir blok diyagram Şekil 5.4’de verilmiştir.



Şekil 5.4. Sınıflandırma sürecine ait bir blok diyagram yapısı

Sınıflandırma sürecinden önce özellikler belirlendi. Dokuz farklı sınıfın birbirinden ayrılma sürecinde önce veriler harmanlandı. Harmanlanan veriler eğitim ve test şeklinde iki guruba ayrıldı. Eğitim aşamasında eğitim verileri kullanılarak ve bir sınıflandırma çeşidi belirlenerek bir model oluşturuldu. Bu modele ait eğitim doğruluğu hesaplandı. Eğitim aşamasında 10 kat katlama (10 fold) yaklaşımı tercih edildi. Bu verilerin 10 sete bölüdüğü anlamına gelmektedir. 9 veri seti eğitilmiş ve kalan 1 veri seti test için kullanılmıştır. İşlem 10 kez tekrarlandı ve ortalama doğruluk alındı. Oluşturulan model test verilerinin sınıflandırılmasında kullanıldı. Sınıflandırma aşamasında MATLAB fonksiyonları ve Classification Learner yazılımı kullanıldı. Test verilerinin gerçek sınıfları ve test aşamasında belirlenen sınıfları karşılaştırıldı. Bu aşamanın sonunda hassaslık, özgünlük ve test doğruluğu değerleri belirlendi.

BÖLÜM 6. SONUÇLAR

Elektrik enerjisinin üretim, iletim ve dağıtım aşamasını içeren sistem insanlık tarafından oluşturulmuş en büyük dinamik sistemlerden birisidir. Elektrik genellikle tüketim merkezinden uzak bir yerde üretilir. Büyük nüfus yoğunluğu olan bölgelere ve sanayi bölgelerine yüksek gerilim hatları ile taşınır. Dağıtım aşamasında ise gerilim seviyesi tüketicilerin ihtiyaç duyduğu seviyeye indirgenir. Güç sistemleri birbirleriyle daha büyük sistemler oluşturacak şekilde birleştirilirler. Bu şekilde güç iletiminin kararlılığı ve güvenilirliği artar. Enterkonnekte güç sistemlerinin amacı, kullanıcılara emniyetli, güvenilir ve temiz enerji sağlamaktır. Tüketicilere sabit şebeke frekansında düzgün bir sinüsoidal şekilli uç gerilimi sağlanmalıdır. Ancak çeşitli nedenlerle bu sağlanamayabilir.

Bu tezde elektriğin iletim ve dağıtım sırasında tespit edilen güç kalitesindeki bozulmaların sınıflandırılması hedeflenmiştir. Diğer bir deyişle güç kalitesindeki bozulmayı belirlemek ve belirlenen bu bozukluğa önlem alma imkânı sağlamak amaçlanmıştır. Bunun için özellik çıkarımı aşamasında dalgacık dönüşümünden yararlanılmıştır. Farklı dalgacık türleri karşılaştırılarak en uygun dalgacık türünün belirlenmesi için analizler pek çok kere tekrarlanmıştır. Bu aşamada incelediğimiz dalgacık türleri Haar, Meyer, db2, db4 ve db6'dır. Ayrıştırılan sinyale ait bilginin çoğunu koruyan değişkenlerin türetilmesi ve seçilen özelliklerin azaltılması için Temel bileşenler analizi yönteminin kullanılması tercih edilmiştir. Böylece özellik sayısı azaltılarak sınıflandırma sürecinin daha kolay ve hızlı bir şekilde yapılması amaçlanmıştır. Sınıflandırıcı olarak tek bir yonteme bağılı kalımadı ve 21 farklı sınıflandırma yöntemini en uygun sınıflandırma yöntemini bulmak için test edildi. Sınıflandırma aşaması için güç kalitesi bozulma işaretlerini içeren 900 tane 1,2 saniyelik sinyal oluşturulmuştur. Bu veri tabanında dokuz farklı sınıf bulunmaktadır. Bu sınıflar harmonikler, gerilim çökmesi, gerilim yükselmesi, gerilim kesintisi,

gerilim dalgalanmaları, gerilim titremesi, normal 50 Hz sinüs dalgası, gerilim çökmesine ek olarak harmonikler, gerilim yükselmesine ek olarak harmonikler şeklindedir. Bu veri tabanının yarısı eğitim ve diğer yarısı test aşamasında kullanıldı.

Haar dalgacık 8. seviye ayrıştırılmasından elde edilen özelliklerin değişik sınıflandırma yöntemleri kullanılarak 9 farklı sınıfa ayrılmasından elde edilen performans sonuçları Tablo 6.1’de verilmiştir. Bu tabloya bakarak en yüksek başarı değeri Hassas K En Yakın Komşu sınıflandırma yönteminden elde edilmiştir. Eğitim Doğruluğu % 97,1, Hassaslık değeri 0,97, Özgünlük değeri 1,00, Test Doğruluğu % 96,4 olarak bulunmuştur. Ortalama değerler sırasıyla Eğitim Doğruluğu % 87,6, Hassaslık değeri 0,64, Özgünlük değeri 0,98, Test Doğruluğu % 86,8 olarak bulunmuştur.

Meyer dalgacık 8. seviye ayrıştırılmasından elde edilen özelliklerin değişik sınıflandırma yöntemleri kullanılarak 9 farklı sınıfa ayrılmasından elde edilen performans sonuçları Tablo 6.2’de verilmiştir. Bu tabloya bakarak en yüksek başarı değeri Hassas K En Yakın Komşu sınıflandırma yönteminden elde edilmiştir. Eğitim Doğruluğu % 96,8, Hassaslık değeri 0,95, Özgünlük değeri 1,00, Test Doğruluğu % 95,9 olarak bulunmuştur. Ortalama değerler sırasıyla Eğitim Doğruluğu % 84,9, Hassaslık değeri 0,58, Özgünlük değeri 0,97, Test Doğruluğu % 84,3 olarak bulunmuştur.

db2 dalgacık 8. seviye ayrıştırılmasından elde edilen özelliklerin değişik sınıflandırma yöntemleri kullanılarak 9 farklı sınıfa ayrılmasından elde edilen performans sonuçları Tablo 6.3’de verilmiştir. Bu tabloya bakarak en yüksek başarı değeri Hassas K En Yakın Komşu sınıflandırma yönteminden elde edilmiştir. Eğitim Doğruluğu % 97,1, Hassaslık değeri 0,97, Özgünlük değeri 1,00, Test Doğruluğu % 96,8 olarak bulunmuştur. Ortalama değerler sırasıyla Eğitim Doğruluğu % 84,2, Hassaslık değeri 0,62, Özgünlük değeri 0,94, Test Doğruluğu % 83,6 olarak bulunmuştur.

db4 dalgacık 8. seviye ayrıştırılmasından elde edilen özelliklerin değişik sınıflandırma yöntemleri kullanılarak 9 farklı sınıfa ayrılmasından elde edilen performans sonuçları

Tablo 6.4’de verilmiştir. Bu tabloya bakarak en yüksek başarı değeri Hassas K En Yakın Komşu sınıflandırma yönteminden elde edilmiştir. Eğitim Doğruluğu % 97,9, Hassaslık değeri 0,98, Özgünlük değeri 1,00, Test Doğruluğu % 97,0 olarak bulunmuştur. Ortalama değerler sırasıyla Eğitim Doğruluğu % 85,3, Hassaslık değeri 0,64, Özgünlük değeri 0,95, Test Doğruluğu % 84,3 olarak bulunmuştur.

db6 dalgacık 8. seviye ayrıştırılmasından elde edilen özelliklerin değişik sınıflandırma yöntemleri kullanılarak 9 farklı sınıfa ayrılmasından elde edilen performans sonuçları Tablo 6.5’de verilmiştir. Bu tabloya bakarak en yüksek başarı değeri Hassas K En Yakın Komşu sınıflandırma yönteminden elde edilmiştir. Eğitim Doğruluğu % 97,1, Hassaslık değeri 0,89, Özgünlük değeri 1,00, Test Doğruluğu % 95,9 olarak bulunmuştur. Ortalama değerler sırasıyla Eğitim Doğruluğu % 87,2, Hassaslık değeri 0,67, Özgünlük değeri 0,96, Test Doğruluğu % 86,6 olarak bulunmuştur.

Sınıflandırma Yöntemine göre En Yüksek Başarı gösteren dalgacıklar Tablo 6.6’da verilmiştir. Değişik Dalgacık türlerine ait ortalama performans değerleride Tablo 6.7’de verilmiştir. 21 sınıflandırma yönteminde en sık başarıya ulaşan dalgacık Db6 olarak bulundu. Sırayla incelersek Haar dalgacığı 4 sınıflandırma yönteminde (Kompleks Karar Ağacı, Kosinüs K En Yakın Komşu, Kübik K En Yakın Komşu, Kübik Destek Vektör Makinesi) en yüksek performans değerlerine ulaşmıştır. Meyer dalgacığı 3 sınıflandırma yönteminde (Yüzeysel K En Yakın Komşu, Altuzay KNN, RUS Geliştirilmiş Ağaç) en yüksek performans değerlerine ulaşmıştır. db2 dalgacığı 2 sınıflandırma yönteminde (Ağırlıklı K En Yakın Komşu, Geliştirilmiş Ağaç) en yüksek performans değerlerine ulaşmıştır. db4 dalgacığı 2 sınıflandırma yönteminde (Hassas K En Yakın Komşu, Kuadratik Destek Vektör Makinesi) en yüksek performans değerlerine ulaşmıştır. db6 dalgacığı 10 sınıflandırma yönteminde (Basit Karar Ağacı, Orta Seviye Karar Ağacı, Doğrusal Ayırıcı, Orta Derece K En Yakın Komşu, Torbalama Karar Ağaçları, Altuzay Ayırımı, Doğrusal Destek Vektör Makinesi, Hassas Gauss Destek Vektör Makinesi, Orta Derece Gauss Destek Vektör Makinesi, Yüzeysel Gauss Destek Vektör Makinesi) en yüksek performans değerlerine ulaşmıştır. Değişik Dalgacık türlerine ait ortalama performans değerleri için Tablo 6.7’ye bakarsak Haar dalgacığın diğerlerinden daha iyi performans değerlerine sahip olduğu görülebilir ama db6 dalgacığı ortalama performans değerleri

olarak ikinci sırada ama oldukça yakın deęerlere sahiptir. Tüm dalgacıklar arasında en başarılı deęer eğitim doęruluęu % 97,9 ve test doęruluęu % 97,0 ile hassas K en yakın komşu sınıflandırma yöntemi ve dalgacık türü db4 olarak bulunmuştur. Genel olarak tüm dalgacık türlerinde hassas k en yakın komşu sınıflandırma yöntemi başarılı sonuçlar vermiştir. Haar dalgacığı ile eğitim doęruluęu % 97,1 ve test doęruluęu % 96,4, Meyer dalgacığı ile eğitim doęruluęu % 96,8 ve test doęruluęu % 95,9, db2 dalgacığı ile eğitim doęruluęu % 97,1 ve test doęruluęu % 96,8, db6 dalgacığı ile eğitim doęruluęu % 97,1 ve test doęruluęu % 95,9 performans deęerlerine ulaşılmıştır.

Çalışmanın geliştirilmesi için veri tabanının daha da büyütülmesi, ayrıca sınıflandırma yöntemlerine ait ayarların deęiştirilerek sistemin performansı artırılması ve deęişik programlama dilleri ile program tekrar yazılarak güç kalitesi bozukluklarının daha hızlı tespit edilmesi mümkün olabilir. Ayrıca derin öğrenme yöntemlerinin matlab veya python ortamında kullanılması olası çözümlerden biridir. Ancak derin öğrenmenin ihtiyaç duyduğu geniş veri tabanını sağlayabilmek bir sorundur. Bunun için çeşitli bölgelerde oluşturulacak deney setleri ile elde edilen sinyalleri kullanmanın performansın gerçekçiliğini artıracığı bir gerçektir. Ayrıca derin öğrenme kullanımasındaki engellerden biriside yüksek performanslı bilgisayar ihtiyacıdır. Ancak bu sorun için Google veya Amazon tarafından sağlanan bulut hizmetlerinden yararlanılabilir.

Tablo 6.1. Haar dalgacığı kullanılarak yapılan sınıflandırmanın performans sonuçları.

Sınıflandırma Yöntemi	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Kompleks Karar Ağacı	96,1	0,96	1,00	95,0
Orta Seviye Karar Ağacı	92,5	0,74	0,99	91,2
Basit Karar Ağacı	83,0	0,40	1,00	81,5
Doğrusal Ayırıcı	78,3	0,40	0,94	77,5
Hassas K En Yakın Komşu	97,1	0,97	1,00	96,4
Orta Derece K En Yakın Komşu	92,9	0,86	0,99	91,9
Yüzeysel K En Yakın Komşu	75,0	0,20	1,00	75,0
Kosinüs K En Yakın Komşu	90,4	0,75	1,00	90,2
Kübik K En Yakın Komşu	92,7	0,83	0,99	91,9
Ağırlıklı K En Yakın Komşu	96,2	0,89	1,00	95,0
Geliştirilmiş Ağaç	96,4	1,00	0,99	95,0
Torbalama Karar Ağaçları	95,6	0,91	1,00	95,0
Altuzay Ayırımı	75,9	0,27	0,97	75,6
Altuzay KNN	95,6	0,89	1,00	95,1
RUS Geliştirilmiş Ağaç	84,0	0,89	0,87	83,2
Doğrusal Destek Vektör Makinesi	77,4	0,34	0,98	76,9
Kuadratik Destek Vektör Makinesi	86,0	0,58	0,97	85,6
Kübik Destek Vektör Makinesi	87,4	0,58	0,98	86,9
Hassas Gauss Destek Vektör Makinesi	87,8	0,44	0,99	86,9
Orta Derece Gauss Destek Vektör Makinesi	83,3	0,35	0,98	81,9
Yüzeysel Gauss Destek Vektör Makinesi	76,0	0,21	1,00	75,7

Tablo 6.2. Meyer dalgacığı kullanılarak yapılan sınıflandırmanın performans sonuçları.

Sınıflandırma Yöntemi	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Kompleks Karar Ağacı	95,9	1,00	0,99	94,4
Orta Seviye Karar Ağacı	93,0	0,89	0,98	92,5
Basit Karar Ağacı	80,9	0,33	0,98	80,0
Doğrusal Ayırıcı	74,3	0,21	0,94	73,8
Hassas K En Yakın Komşu	96,8	0,95	1,00	95,9
Orta Derece K En Yakın Komşu	90,8	0,73	0,99	90,7
Yüzeysel K En Yakın Komşu	75,7	0,21	1,00	75,1
Kosinüs K En Yakın Komşu	88,9	0,70	0,98	88,2
Kübik K En Yakın Komşu	90,8	0,73	0,99	90,6
Ağırlıklı K En Yakın Komşu	95,8	0,89	1,00	95,0
Geliştirilmiş Ağaç	95,4	0,89	1,00	95,0
Torbalama Karar Ağaçları	95,4	0,91	1,00	95,0
Altuzay Ayırımı	73,8	0,18	0,98	73,8
Altuzay KNN	95,7	0,90	1,00	95,2
RUS Geliştirilmiş Ağaç	87,1	0,89	0,89	85,7
Doğrusal Destek Vektör Makinesi	77,2	0,29	0,98	76,3
Kuadratik Destek Vektör Makinesi	84,4	0,45	0,95	83,2
Kübik Destek Vektör Makinesi	60,3	0,47	0,65	58,2
Hassas Gauss Destek Vektör Makinesi	79,4	0,23	0,97	80,0
Orta Derece Gauss Destek Vektör Makinesi	75,9	0,22	1,00	75,7
Yüzeysel Gauss Destek Vektör Makinesi	75,4	0,20	1,00	75,0

Tablo 6.3. db2 dalgacıđı kullanılarak yapılan sınıflandırmanın performans sonuçları.

Sınıflandırma Yöntemi	Eđitim Doğruluđu	Hassaslık	Özgünlük	Test Doğruluđu
Kompleks Karar Ağacı	95,3	1,00	0,98	95,0
Orta Seviye Karar Ağacı	95,2	1,00	0,97	95,0
Basit Karar Ağacı	77,7	0,27	0,98	77,5
Dođrusal Ayırıcı	76,9	0,29	0,96	76,3
Hassas K En Yakın Komşu	97,1	0,97	1,00	96,8
Orta Derece K En Yakın Komşu	92,1	0,83	0,98	91,3
Yüzeysel K En Yakın Komşu	75,0	0,20	1,00	75,0
Kosinüs K En Yakın Komşu	90,2	0,70	0,99	90,0
Kübik K En Yakın Komşu	91,5	0,83	0,98	91,3
Ađırlıklı K En Yakın Komşu	96,3	0,90	1,00	95,1
Geliştirilmiş Ağaç	96,5	1,00	0,99	95,1
Torbalama Karar Ağaçları	95,5	1,00	0,98	95,0
Altuzay Ayırımı	76,9	0,17	0,97	76,3
Altuzay KNN	95,5	0,89	1,00	95,0
RUS Geliştirilmiş Ağaç	81,4	0,89	0,82	80,7
Dođrusal Destek Vektör Makinesi	77,6	0,31	0,97	76,9
Kuadratik Destek Vektör Makinesi	85,9	0,43	0,98	85,7
Kübik Destek Vektör Makinesi	28,5	0,60	0,21	27,5
Hassas Gauss Destek Vektör Makinesi	85,3	0,29	1,00	84,4
Orta Derece Gauss Destek Vektör Makinesi	82,3	0,23	0,98	81,3
Yüzeysel Gauss Destek Vektör Makinesi	75,2	0,20	1,00	75,0

Tablo 6.4. db4 dalgacıđı kullanılarak yapılan sınıflandırmanın performans sonuçları.

Sınıflandırma Yöntemi	Eđitim Doğruluđu	Hassaslık	Özgünlük	Test Doğruluđu
Kompleks Karar Ağacı	94,9	0,97	0,98	94,4
Orta Seviye Karar Ağacı	94,7	0,97	0,98	93,8
Basit Karar Ağacı	78,7	0,27	1,00	78,2
Dođrusal Ayırıcı	79,2	0,38	0,98	78,8
Hassas K En Yakın Komşu	97,9	0,98	1,00	97,0
Orta Derece K En Yakın Komşu	92,8	0,80	0,99	91,3
Yüzeysel K En Yakın Komşu	75,4	0,20	1,00	75,0
Kosinüs K En Yakın Komşu	89,8	0,75	0,98	88,8
Kübik K En Yakın Komşu	91,5	0,91	0,99	91,3
Ađırlıklı K En Yakın Komşu	95,7	0,89	1,00	95,0
Geliştirilmiş Ağaç	95,8	0,89	1,00	95,0
Torbalama Karar Ağaçları	95,5	0,95	0,99	95,0
Altuzay Ayırımı	75,6	0,19	0,98	75,0
Altuzay KNN	95,4	0,89	1,00	95,0
RUS Geliştirilmiş Ağaç	84,4	0,89	0,87	84,3
Dođrusal Destek Vektör Makinesi	81,5	0,33	0,98	80,6
Kuadratik Destek Vektör Makinesi	88,8	0,66	0,99	88,2
Kübik Destek Vektör Makinesi	42,7	0,69	0,26	33,2
Hassas Gauss Destek Vektör Makinesi	86,5	0,37	1,00	86,3
Orta Derece Gauss Destek Vektör Makinesi	79,7	0,22	1,00	78,8
Yüzeysel Gauss Destek Vektör Makinesi	75,2	0,20	1,00	75,0

Tablo 6.5. db6 dalgacıđı kullanılarak yapılan sınıflandırmanın performans sonuçları.

Sınıflandırma Yöntemi	Eđitim Doğruluđu	Hassaslık	Özgünlük	Test Doğruluđu
Kompleks Karar Ağacı	95,0	0,89	1,00	94,7
Orta Seviye Karar Ağacı	95,7	0,95	1,00	95,1
Basit Karar Ağacı	83,1	0,45	0,98	81,9
Dođrusal Ayırıcı	85,1	0,46	0,99	84,4
Hassas K En Yakın Komđu	97,1	0,89	1,00	95,9
Orta Derece K En Yakın Komđu	93,2	0,89	0,99	92,5
Yüzeysel K En Yakın Komđu	75,3	0,20	1,00	75,0
Kosinüs K En Yakın Komđu	87,1	0,75	0,96	86,9
Kübik K En Yakın Komđu	92,3	0,83	0,99	91,8
Ađırlıklı K En Yakın Komđu	96,1	0,89	1,00	95,1
Geliştirilmiş Ağaç	95,5	0,90	1,00	95,0
Torbalama Karar Ağaçları	95,9	1,00	0,99	95,0
Altuzay Ayırımı	82,2	0,49	0,94	81,9
Altuzay KNN	95,6	0,89	1,00	95,0
RUS Geliştirilmiş Ağaç	85,4	0,89	0,87	85,0
Dođrusal Destek Vektör Makinesi	81,7	0,34	0,97	81,3
Kuadratik Destek Vektör Makinesi	88,5	0,58	0,98	88,1
Kübik Destek Vektör Makinesi	50,4	0,68	0,49	49,4
Hassas Gauss Destek Vektör Makinesi	89,3	0,55	0,99	88,8
Orta Derece Gauss Destek Vektör Makinesi	86,6	0,37	1,00	85,7
Yüzeysel Gauss Destek Vektör Makinesi	80,6	0,24	1,00	80,0

Tablo 6.6. Sınıflandırma Yöntemine göre En Yüksek Başarı gösteren dalgacıklar.

Sınıflandırma Yöntemi	Eğitim Doğruluğu	Test Doğruluğu	En Başarılı Dalgacık
Kompleks Karar Ağacı	95,0	94,7	Haar
Orta Seviye Karar Ağacı	95,7	95,0	db6
Basit Karar Ağacı	83,1	81,9	db6
Doğrusal Ayırıcı	85,1	84,4	db6
Hassas K En Yakın Komşu	97,9	97,0	db4
Orta Derece K En Yakın Komşu	93,2	92,5	db6
Yüzeysel K En Yakın Komşu	75,7	75,1	Meyer
Kosinüs K En Yakın Komşu	90,4	90,2	Haar
Kübik K En Yakın Komşu	92,7	91,9	Haar
Ağırlıklı K En Yakın Komşu	96,3	95,1	db2
Geliştirilmiş Ağaç	96,5	95,1	db2
Torbalama Karar Ağaçları	95,9	95,1	db6
Altuzay Ayırımı	82,2	81,9	db6
Altuzay KNN	95,7	95,2	Meyer
RUS Geliştirilmiş Ağaç	87,1	85,7	Meyer
Doğrusal Destek Vektör Makinesi	81,7	81,3	db6
Kuadratik Destek Vektör Makinesi	88,8	88,2	db4
Kübik Destek Vektör Makinesi	87,4	86,9	Haar
Hassas Gauss Destek Vektör Makinesi	89,3	88,8	db6
Orta Derece Gauss Destek Vektör Makinesi	86,6	85,7	db6
Yüzeysel Gauss Destek Vektör Makinesi	80,6	80,0	db6

Tablo 6.7. Değişik Dalgacık türlerine ait ortalama performans değerleri.

Dalgacık	Eğitim Doğruluğu	Hassaslık	Özgünlük	Test Doğruluğu
Haar	87,6	0,64	0,98	86,8
Meyer	84,9	0,58	0,97	84,3
db2	84,2	0,62	0,94	83,6
db4	85,3	0,64	0,95	84,3
db6	87,2	0,67	0,96	86,6



KAYNAKLAR

- [1] Poisson, O., Rioual, P., & Meunier, M., Detection and measurement of power quality disturbances using wavelet transform. In Harmonics and Quality of Power Proceedings, 1998. Proceedings. 8th International Conference On (Vol. 2, pp. 1125-1130). IEEE, 1998.
- [2] Poisson, O., Rioual, P., & Meunier, M., New signal processing tools applied to power quality analysis. IEEE transactions on Power Delivery, 14(2), 561-566, 1999.
- [3] Dash, P. K., Panigrahi, B. K., & Panda, G., Power quality analysis using S-transform. IEEE Transactions on power delivery, 18(2), 406-411, 2003.
- [4] Kanitpanyacharoen, W., & Premrudeepreechacharn, S., Power quality problem classification using wavelet transformation and artificial neural networks. In Power Systems Conference and Exposition, 2004. IEEE PES (pp. 1496-1501). IEEE, 2004.
- [5] Kim, H., Lee, J., Choi, J., Lee, S., & Kim, J., Power quality monitoring system using wavelet-based neural network. In Power System Technology, 2004. PowerCon 2004. 2004 International Conference on (Vol. 1, pp. 453-458). IEEE, 2004.
- [6] Kaewarsa, S., & Attakitmongkol, K., Power Quality Disturbance Recognition Using Wavelet-Based Neural Networks. In TENCON 2005 2005 IEEE Region 10 (pp. 1-5). IEEE, 2005.
- [7] Tong, W., Song, X., Lin, J., & Zhao, Z., Detection and classification of power quality disturbances based on wavelet packet decomposition and support vector machines. In Signal Processing, 2006 8th International Conference on (Vol. 4). IEEE, 2006.

- [8] Basu, M., & Basu, B., Analysis of power quality (PQ) signals by continuous wavelet transform. In Power Electronics Specialists Conference, 2007. PESC 2007. IEEE (pp. 2614-2618). IEEE, 2007.
- [9] Hua, L., Yuguo, W., & Wei, Z., Power quality disturbances detection and classification using complex wavelet transformation and artificial neural network. In Control Conference, 2007. CCC 2007. Chinese (pp. 208-212). IEEE, 2007.
- [10] Hernandez-Perez, J. F., Vela-Arviso, D., Rodriguez-Lelis, J. M., Orta-Acuna, J. L., Tolosa-Mata, D., & Vargas-Trevino, M., A Morlet Wavelet Signal Analysis with a Daubechies Filter for Power Quality Disturbances. In Electronics, Robotics and Automotive Mechanics Conference, 2007. CERMA 2007 (pp. 675-680). IEEE, 2007.
- [11] Jayasree, D. D., Classification of power quality disturbance signals using FFT, STFT, wavelet transforms and neural networks-A comparative analysis. In Conference on Computational Intelligence and Multimedia Applications, 2007. International Conference on (Vol. 1, pp. 335-340). IEEE, 2007.
- [12] Meyer, S. K., Power quality event analysis using wavelet feature based fuzzy classification. In Transmission and Distribution Conference and Exposition, 2008. T&D. IEEE/PES (pp. 1-6). IEEE, 2008.
- [13] Ruijuan, J., & Chunxia, X., Power quality event detection and recognition using wavelet analysis and intelligent neural network. In Control Conference, 2008. CCC 2008. 27th Chinese (pp. 486-489). IEEE, 2008.
- [14] Chandel, A. K., Guleria, G., & Chandel, R., Classification of power quality problems using wavelet based artificial neural network. In Transmission and Distribution Conference and Exposition, 2008. T&D. IEEE/PES (pp. 1-5). IEEE, 2008.
- [15] Nath, S., Dey, A., & Chakrabarti, A., Detection of power quality disturbances using wavelet transform. World Academy of Science, Engineering and Technology, 49, 869-873, 2009.
- [16] Vega, V., Kagan, N., Ordonez, G., & Duarte, C., Automatic power quality disturbance classification using wavelet, support vector machine and artificial

neural network. In Electricity Distribution-Part 1, 2009. CIRED 2009. 20th International Conference and Exhibition on (pp. 1-4). IET, 2009.

- [17] Nath, S., & Sinha, P., Measurement of power quality under nonsinusoidal condition using wavelet and fuzzy logic. In Power Systems, 2009. ICPS'09. International Conference on (pp. 1-6). IEEE, 2009.
- [18] Zhao, Y., Xu, Y., Xiao, X., Zhu, Y., & Guo, C., Power Quality Disturbances Identification Based on dq Conversion, Wavelet Transform and FFT. In Power and Energy Engineering Conference (APPEEC), 2010 Asia-Pacific (pp. 1-4). IEEE, 2010.
- [19] Milchevski, A., & Taskovski, D., Classification of power quality disturbances using wavelet transform and SVM decision tree. In Electrical Power Quality and Utilisation (EPQU), 2011 11th International Conference on (pp. 1-5). IEEE, 2011.
- [20] Singh, B., Shahani, D. T., & Kumar, R., Recognition of power quality events using DT-DWT based Complex Wavelet Transform. In Power India Conference, 2012 IEEE Fifth (pp. 1-4). IEEE, 2012.
- [21] Khoa, N. M., Viet, D. T., & Hieu, N. H., Classification of power quality disturbances using wavelet transform and k-nearest neighbor classifier. In Industrial Electronics (ISIE), 2013 IEEE International Symposium on (pp. 1-4). IEEE, 2013.
- [22] Upadhyaya, S., & Mohanty, S., Power quality disturbance detection using wavelet based signal processing. In India conference (INDICON), 2013 annual IEEE (pp. 1-6). IEEE, 2013.
- [23] Tuljapurkar, M., & Dharme, A. A., Wavelet based signal processing technique for classification of power quality disturbances. In Signal and Image Processing (ICSIP), 2014 Fifth International Conference on (pp. 337-342). IEEE, 2014.
- [24] Kamble, S., & Dupare, I., Detection of power quality disturbances using wavelet transform and artificial neural network. In Emerging Research Areas: Magnetics, Machines and Drives (AICERA/iCMMD), 2014 Annual International Conference on (pp. 1-5). IEEE, 2014.

- [25] Shinde, P. P., Narkhede, D. R., Munje, R. K., & Kushare, B. E., Voltage events detection using wavelet transform for power quality applications. In India Conference (INDICON), 2014 Annual IEEE (pp. 1-6). IEEE, 2014.
- [26] Naik, C. A., & Kundu, P., Analysis of Power Quality disturbances using wavelet packet transform. In Power Electronics (IICPE), 2014 IEEE 6th India International Conference on (pp. 1-4). IEEE, 2014.
- [27] Sebastian, P., & D'Sa, P. A., Implementation of a Power Quality signal classification system using wavelet based energy distribution and neural network. In Power and Advanced Control Engineering (ICPACE), 2015 International Conference on (pp. 157-161). IEEE, 2015.
- [28] Ijaz, M., Shafiullah, M., & Abido, M. A., Classification of power quality disturbances using Wavelet Transform and Optimized ANN. In Intelligent System Application to Power Systems (ISAP), 2015 18th International Conference on (pp. 1-6). IEEE, 2015.
- [29] Alshahrani, S., Abbod, M., Alamri, B., & Taylor, G., Evaluation and classification of power quality disturbances based on discrete Wavelet Transform and artificial neural networks. In Power Engineering Conference (UPEC), 2015 50th International Universities (pp. 1-5). IEEE, 2015.
- [30] Khokhar, S., Zin, A. M., Mokhtar, A. S., Bhayo, M. A., & Naderipour, A., Automatic classification of single and hybrid power quality disturbances using Wavelet Transform and Modular Probabilistic Neural Network. In Energy Conversion (CENCON), 2015 IEEE Conference on (pp. 457-462). IEEE, 2015.
- [31] Bhuiyan, S., Khan, J., & Murphy, G., Wavelet packet decomposition for power quality monitoring in smart grid. In Industry Applications Society Annual Meeting, 2016 IEEE (pp. 1-8). IEEE, 2016.
- [32] Singh, S., Jain, B., & Jain, S., Wavelet based real-time power quality monitoring. In Electrical and Computer Engineering (CCECE), 2016 IEEE Canadian Conference on (pp. 1-6). IEEE, 2016.

- [33] Naik, C., Hafiz, F., Swain, A., & Kar, A. K., Classification of power quality events using wavelet packet transform and extreme learning machine. In Power Electronics Conference (SPEC), IEEE Annual Southern (pp. 1-6). IEEE, 2016.
- [34] Sharma, A. K., Mahela, O. P., & Ola, S. R., Detection of Power quality disturbances using discrete wavelet transform. In Electrical Power and Energy Systems (ICEPES), International Conference on (pp. 450-455). IEEE, 2016.
- [35] Liu, Z., Cui, Y., & Li, W., A classification method for complex power quality disturbances using EEMD and rank wavelet SVM. IEEE Transactions on Smart Grid, 6(4), 1678-1685, 2015.
- [36] Thiagarajan, V., & Subramaniam, N. P., Wavelet approach and support vector networks based power quality events recognition and categorisation. In Signal Processing, Communication, Power and Embedded System (SCOPES), 2016 International Conference on (pp. 1667-1671). IEEE, 2016.
- [37] Tomak, Ö., Mengi, O. Ö. Complex Tree Classification of Voltage Sag and Interruption using theory of wavelet. In: 1st International Mediterranean Science and Engineering Congress., 4507-4511, 2016.
- [38] Bosnic, J. A., Petrovic, G., Putnik, A., & Mostarac, P., Power quality disturbance classification based on wavelet transform and support vector machine. In Measurement, 2017 11th International Conference on (pp. 9-13). IEEE, 2017.
- [39] Markovska, M., & Taskovski, D., Optimal wavelet based feature extraction and classification of power quality disturbances using random forest. In Smart Technologies, IEEE EUROCON 2017-17th International Conference on (pp. 855-859). IEEE, 2017.
- [40] Tomak, Ö., Mengi, O. Ö. K-Nearest Neighbor Classification of Harmonics Using Akaike Information Criterion. Karadeniz Fen Bilimleri Dergisi, Cilt 7, Sayı 1, 1 – 8, 2017.
- [41] Dugan, R. C., McGranaghan, M. F., & Beaty, H. W., Electrical power systems quality. New York, NY: McGraw-Hill, c1996, 1996.

- [42] Fehr, R., Harmonics Made Simple. Electrical Construction and Maintenance, 103(1), 2004.
- [43] Moravej, Z., Abdoos, A. A., & Pazoki, M., Detection and classification of power quality disturbances using wavelet transform and support vector machines. Electric Power Components and Systems, 38(2), 182-196, 2009.
- [44] McGranaghan, M. F., Mueller, D. R., & Samotyj, M. J., Voltage sags in industrial systems. IEEE Transactions on industry applications, 29(2), 397-403, 1993.
- [45] Bollen, M. H., Understanding power quality problems. Piscataway, NJ, USA: IEEE, 1, 1-35, 2000.
- [46] Kazibwe, W. E., Sendaula, M. H., Electric power quality control techniques. New York: Van Nostrand Reinhold, 1993, p. 11, 1993.
- [47] Atasal, M., Güç Kalitesi Ve Fliker, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2000.
- [48] Mallat S., A wavelet tour of signal processing: the sparse way. Academic press, 2008.
- [49] Graps, A., An Introduction to Wavelets, IEEE Computational Science and Engineering, vol. 2, num. 2. IEEE Computer Society, Los Alamitos-CA, USA, 1995.
- [50] Akansu, A. N., & Haddad, R. A., Multiresolution signal decomposition: transforms, subbands, and wavelets. Academic Press, 2001.
- [51] www.mathworks.com., Erişim tarihi: 01.11.2017.
- [52] Rokach, L., & Maimon, O., Data mining with decision trees: theory and applications, 2008.

- [53] Tomak, Ö., & Kayıkçioğlu, T., Comparison of different classification algorithms using easily calculated features. In Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT), 2017 (pp. 1-4). IEEE, 2017.
- [54] Jolliffe, I., Principal component analysis. John Wiley & Sons, Ltd, 2002.
- [55] Hsu, D., Kakade, S. M., & Zhang, T., A spectral algorithm for learning hidden Markov models. Journal of Computer and System Sciences, 78(5), 1460-1480, 2012.



ÖZGEÇMİŞ

Özgür TOMAK, 1977 yılında Ankara’da doğdu. 1995 yılında başladığı Orta Doğu Teknik Üniversitesi Elektrik-Elektronik Mühendislik Bölümü’nü 2000 yılında bitirdi. 2015 yılında Giresun Üniversitesi, Mühendislik Fakültesi, Enerji Sistemleri Mühendisliği Bölümü’nde Yüksek Lisans Programı’na başladı. 2007 yılında Giresun Üniversitesi’nde Öğretim Görevlisi olarak çalışmaya başladı. Halen Öğretim Görevlisi olarak görev yapmaktadır.