

**MONTAJLI OTOMOTİV PARÇALARINDA HOŞA
GİTMEYEN SES KALİTESİNİN BELİRLENMESİ İÇİN
ÇOK KATMANLI YAPAY SİNİR AĞI UYGULAMASI**

İsmail TEPEDAĞ



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MONTAJLI OTOMOTİV PARÇALARINDA HOŞA GİTMEYEN SES
KALİTESİNİN BELİRLENMESİ İÇİN ÇOK KATMANLI YAPAY SİNİR AĞI
UYGULAMASI**

İsmail TEPEDAĞ
0000-0003-4068-4040

Prof. Dr. Erdal EMEL
(Danışman)

YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2021
Her Hakkı Saklıdır

TEZ ONAYI

İsmail TEPEDAĞ tarafından hazırlanan “MONTAJLI OTOMOTİV PARÇALARINDA HOŞA GİTMEYEN SES KALİTESİNİN BELİRLENMESİ İÇİN ÇOK KATMANLI YAPAY SİNİR AĞI UYGULAMASI” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS** olarak kabul edilmiştir.

Danışman : Prof. Dr. Erdal EMEL

Başkan : Prof. Dr. Erdal EMEL İmza
0000-0002-9220-7353
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

Üye : Doç. Dr. Ali Yurdun ORBAK İmza
0000-0002-4921-4275
Bursa Uludağ Üniversitesi ,
Mühendislik Fakültesi Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

Üye : Doç.Dr. Aytaç YILDIZ İmza
0000-0002-0729-633X
Bursa Teknik Üniversitesi,
Mühendislik ve Doğa Bilimleri Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü

.././.....

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

.../.../.....

İsmail TEPEDAĞ

ÖZET

Yüksek Lisans/Doktora Tezi

MONTAJLI OTOMOTİV PARÇALARINDA HOŞA GİTMİYEN SES KALİTESİNİN BELİRLENMESİ İÇİN ÇOK KATMANLI YAPAY SİNİR AĞI UYGULAMASI

İsmail TEPEDAĞ

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Erdal EMEL

Maliyet, kalite ve üretim verimliliğinin şirketin geleceğini ve rekabet gücünü belirlediği otomotiv endüstrisinde otomatik montaj hatları çok önemli bir üretim yöntemidir. Yüksek ilk yatırım maliyetlerine rağmen otomatik prosesler, montaj hatlarında düşük üretim maliyeti, yüksek üretim hızı ve yüksek kalite standardizasyonu sağlar. Bu tür otomatik montaj hatları, üretilen ürünün kalite açısından tüm gerekliliklerini sağlayacak kalite kontrol süreçlerini de içermelidir.

Bu çalışmanın amacı, bir otomatik montaj hattında üretilen motorlu yan ayna hareket mekanizmasının operatöre dayalı ses kalite kontrolü yerine kullanılacak bir yapay sinir ağı tabanlı algılama sistemi geliştirilmesidir.

Kalite kontrolü yapılan motorlu mekanizmaların ürettiği gerçek ses verilerinden zaman ve frekans uzayında elde edilen özniteliklerin girdi olarak kullanıldığı bu çalışmada, üç gizli katmanlı bir yapay sinir ağı oluşturularak, yeterli sayıda örnek ile eğitim ve geçerleme gerçekleştirilmiştir.

Geliştirilen yapay sinir ağı tabanlı yaklaşım, erişilen %96 başarılı algılama oranı ile insan kontrolünün kaldırılması için gerekli güvenilirliği sağlamıştır. Elde edilen bulguların başka çalışmalarla da doğrulanması halinde bu yaklaşım, sübjektif kalite kontrol yaklaşımlarına alternatif oluşturmaktadır.

Anahtar Kelimeler: Ses Kalitesi, Yapay Sinir Ağı, Sübjektif Kalite Kontrol, Powerfold Mekanizması, Otomotiv

2020, vii + 149 sayfa.

ABSTRACT

MSc Thesis

AN APPLICATION OF A MULTI LAYER NEURAL NETWORK TO DISCRIMINATE NONCONFORMING SOUND QUALITY OF ASSEMBLED AUTOMOTIVE COMPONENTS

İsmail TEPEDAĞ

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Industrial Engineering

Supervisor: Prof. Dr. Erdal EMEL

Automated assembly lines is a very important production method in the automotive industry where cost, quality and production efficiency determine the future and the competitiveness of a company. Despite high initial investment costs, automated processes provide assembly lines with low production costs, high production speeds and quality standards. Such automated assembly lines must consist of quality control processes to meet all the quality requirements of the products produced.

This study aims to develop an artificial neural network based recognition system capable of eliminating the need for a human based quality control approach to control the sound emitted by the motorized side mirror movement mechanisms produced in an automated assembly line.

In this study, a three-hidden layer artificial neural network was trained and validated using the features extracted in time and frequency domain of a sufficient number of real sound samples emitted by the motor mechanisms during their quality control.

The artificial neural network based approach achieving a 96% recognition rate, provided sufficient reliability to replace the human based control approach. Provided that the obtained results are confirmed by other studies, the proposed approach offers an alternative to subjective quality control approaches.

Key words: Quality Control, Neural Network, Sound Quality, Automotive, Powerfold Mechanism

2020, vii + 149 pages.

TEŐEKKÜR

Öncelikli olarak 45 yařından sonra bu tezi bitirmek için kendilerine ayırmam gereken zamandan fedakârlık ederek bana sonsuz destek olan eőime ve çocuklarıma teőekkürlerimi sunarım.

Böylesine ilginç bir tez konusunu önererek bana yeni bir bakış açısı kazandıran değerli arkadaşım Ficosa Türkiye Ar-Ge Direktörü Önder Özfıdan 'a ve bu çalışma için gerekli izinleri vererek desteğini esirgemeyen Ficosa Otomotiv'e ve çalışanlarına teőekkürlerimi sunarım.

Yüksek Lisans eğitimi ve tez çalışmasının tüm gelişim aşamalarında, bilgi ve yönlendirmeleri, sağladığı akademik imkanlar ve verdiği çok değerli zamanı ile hedefe ulaşmamı sağlayan Sayın Prof. Dr. Erdal Emel'e özel teőekkürlerimi sunarım.

İsmail TEPEDAĞ

.../.../.....

İÇİNDEKİLER

	Sayfa
ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	iv
ŞEKİLLER DİZİNİ.....	v
ÇİZELGELER DİZİNİ.....	vi
1. GİRİŞ.....	vii
1.1.Çalışmanın Amacı.....	1
1.2.Kullanılan Metodoloji.....	3
1.3.Tezin Organizasyonu.....	3
2. KAYNAK ARAŞTIRMASI.....	5
3. MATERYAL ve YÖNTEM.....	8
3.1.Problemin Tanımlanması.....	8
3.2. Ayna katlama Mekanizması Tasarımı.....	12
3.3. Ses Kalite Problemleri.....	13
3.4. Ses Sinyallerinin İşlenmesi.....	14
3.5. Öznitelik Üretimi.....	15
3.5.1.Zaman Uzayı Temel Öznitelikleri.....	15
3.5.2.Kesikli Fourier Dönüşümü (DFT).....	18
3.5.3. Otokorelasyon (Autocorrelation).....	21
3.5.4.Ses Basınç Seviyesi (dB).....	22
3.5.5. Öznitelik Seçimi.....	23
3.5.6.Yapay Sinir Ağı (YSA).....	27
3.6.Yöntem.....	34
3.6.1.Ses Kayıt ve Veri Seti Hazırlama.....	35
3.6.2.Ses Ön İşleme.....	36
3.6.3.Öznitelik Üretme.....	38
3.6.4.Öznitelik Seçme ve Azaltma.....	40
3.6.5.Yapay Sinir Ağı Oluşturma, Eğitim ve Validasyon ve Performans Ölçümü.....	41
3.6.6.Yeni Ses Dosyaları ile YSA Testi.....	44
3.6.7.Etkinlik Ölçüm ve Değerlendirme.....	44
4. BULGULAR.....	46
4.1.Yazılım ve Donanım.....	46
4.2.Verit Seti.....	46
4.3.Analiz.....	46
5. TARTIŞMA ve SONUÇ.....	52
KAYNAKLAR.....	53
EKLER.....	55
EK 1. Test ve Validasyon dosyaları kalite durumunu gösterir tablo.....	56
EK 2. Seçilmiş ve Hesaplanmış Girdilerin Tamamı.....	60
EK 3. MATLAB ile Yazılmış Programlar.....	61
EK 4. Temiz Oda Sınıflandırmaları.....	75
ÖZGEÇMİŞ.....	76

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
Hz	Hertz
dB	Desibel
Tu	Tone of (1000 Hz, 60 dB) sinusoidal wave
RMS	Root Mean Squares
f_s	Ses dosyasının kayıt edilme hızı Hz cinsindedir..
L_t	Zaman Ağırlıklı ses seviyesi
IF	Anlık Frekans

Kısaltmalar	Açıklama
YSA	Yapay Sinir Ağı
NVH	Noise (Ses), Vibration(Titreşim) and Harshness (Sertlik)
CNN	Convolutional Neural Network (Evrişimsel Yapay Sinir Ağı)
NCA	Neighborhood Component Analysis (Komşuluk Komponent Analizi)
MAX	Maksimum değer ya da Maksimum değeri seçen fonksiyon
AVG	Ortalama Değer ya da Ortalama Değeri hesaplayan fonksiyon
SPL	Ses Basınç Seviyesi
OK	Uygun anlamında kalite durumu
NOK	Uygun değil anlamında kalite durumu
FFT	Hızlı Fourier Dönüşümü
EMD	Ampirik Mod Ayırımı
MIN	Minimum değer ya da Minimum değeri seçen fonksiyon
DtP	Drive To Park (Mekanizmanın Açık halden Kapalı hale hareketi)
PtD	Park To Drive (Mekanizmanın Kapalı halden Açık hale hareketi)

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Uygulama Konusu Üretim Akışı	3
Şekil 3.1. Üretim ve İkinci Kontrol Sonrası Hata Oranları	9
Şekil 3.2. Parametrik Sistemin Karışıklık Tablosu	9
Şekil 3.3. Ayna Katlama Mekanizması ve Aynadaki Yeri	12
Şekil 3.4. Bir Analog Sinyal (Mavi) ve Sayısal Karşılığı (Turuncu).....	14
Şekil 3.5. Spektral Hata.....	19
Şekil 3.6. Hanning Window Uygulaması ile değişen frekans.....	21
Şekil 3.7. Örnek bir 3 katmanlı ileri beslemeli yapay sinir ağı.....	27
Şekil 3.8. Bir Nöronun Yapısı.....	28
Şekil 3.9. İki Nöron Arasındaki Bağlantı.....	29
Şekil 3.10. En çok kullanılan bazı Eşik Fonksiyonları	30
Şekil 3.11 İki Nöron arasındaki İlişki	32
Şekil 3.12. Ses Kalite Problemlerinin Çözümünde Kullanılan Yöntem	34
Şekil 3.13. Ayna açma kapama mekanizmasının Ses Basınç Seviyesi-SPL Değişimi ...	36
Şekil 3.14. Farklı ürün örneklerinde normal ve hatalı ürün için SPL değişimi	37
Şekil 3.15. FFT dönüşümü yapan program kodu	38
Şekil 3.16. NCFS Komşuluk Bileşke Analizi algoritması (Yang, Wang, Zuo, 2012)	41
Şekil 3.17. 65G/18H1/12H2/6H3/6Ç YSA YAPISI	42
Şekil 3.18. Optimum Eğitim Seviyesi.....	43
Şekil 4.1. DtP / Seçilen Öznitelik Sayısı 34 /.....	47
Şekil 4.2. PtD / Seçilen Öznitelik Sayısı 28 /.....	47
Şekil 4.3. DtP Karışıklık Matrisi.....	48
Şekil 4.4. PtD Karışıklık Matrisi.....	49
Şekil 4.5. Eğitim ve Test Çalıştırmaları sonucu Karışıklık matrisleri ve Performans	51
Şekil 4.6. Parametrik Sistem ile YSA Performans Karşılaştırma Tablosu	51

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. Ayna Katlama Mekanizması elemanları tolerans analizi.....	13
Çizelge 3.2. Ses Kalite Problemleri ve Muhtemel Nedenleri	13
Çizelge 3.3. Pencere tipleri ve tercih edilebilirlik durumları	20
Çizelge 3.4. Eşleştirme Tablosundan bir Kesit	36
Çizelge 3.5. Çalışmada Dikkate Alınan Özniteliklerin Tam Listesi	41
Çizelge 4.1. YSA'ya Girdi Olarak Seçilmiş Öznitelikler	50

1. GİRİŞ

1.1.Çalışmanın Amacı

Kalite Kontrol bir imalat şirketinin başarısında çok önemli bir rol üstlenir. Özellikle otomotiv endüstrisinde yükselen standartlar ve rekabet, şirketleri daha iyi çözümler bulmaya yönlendirmektedir. İmalat mükemmelliği yolunda hemen hemen tüm otomotiv ve yan sanayii firmaları bugünün dünden daha iyi olmasına çalışmaktadır.

Otomotiv endüstrisinin amacı daha hızlı, daha güvenilir ve daha sürdürülebilir çıktı elde etmektir. Bu doğrultuda ve teknolojik gelişmelerin yardımı ile “tam otomatik üretim hattı” kavramı zaman içerisinde benimsenmiş ve uygulanmıştır. “Tam otomatik” ile özellikle katma değer yaratan operasyonların makineler tarafından gerçekleştirilmesi amaçlanır. Bu tür tam otomasyon sistemlerinde dahi sistem kontrolü yapan teknisyenler ve malzeme besleyen operatörlere gerek duyulmaktadır. Örneğin, bir tam otomatik montaj sistemi gelen malzemenin kontrolünü ve ardından montaj işlemini yapar. Yaptığı işin kritik özelliklerini kontrol eder (ör. sıkma tork seviyesi) ve izlenebilirlik amaçlı olarak tüm parametreleri kaydeder. Genellikle bu tür tam otomatik sistemlerdeki kontrol kriterleri niceliksel özelliktedir (ör. bir parçanın var olup olmaması, bir ölçünün ölçülen değeri) ancak bazen de niteliksel özelliklerin de kontrolü gerekmektedir (hoşa gitmeyen ses seviyesi ya da fark edilebilen renk ton farkı gibi.)

Ürünün niteliksel kalite parametreleri, sadece tam otomasyon değil manuel ya da yarı otomasyon üretim sistemlerinin de ortak problemidir. Ölçümler subjektif olup, kişiden kişiye değişebilir. Eğitim ve deneyimin önemi artar; ancak yeterli olmayabilir. Görsel ve estetik kalite kontrol süreçleri, 20.yüzyıl boyunca otomotiv endüstrisinde genellikle insanların çalıştığı bir alan olmuştur.

Bu tez kapsamına temel oluşturan problem, gerçek bir üretim ortamından alınmıştır.


Bu çalışmada, sözkonusu tam otomatik montaj hattında üretilen ayna katlama mekanizmalarının hoşa gitmeyen ses kalitesi ölçümü ele alınmıştır. Mevcut sistemde var olan parametrik kalite kontrol mekanizmasının performans ölçütleri, işletmenin Kalite

Bölümünden alınan bilgilerle hesaplanmıştır. Söz konusu performans ölçütleri Bölüm 3.1.'de detaylandırılmıştır. Firma otomatik çalışan parametrik sistemin kalite kontrol performansı yetersiz olduğu için üretilen bitmiş ürünlere sevkiyat öncesi, hat dışında bir başka kalite kontrol aşaması daha uygulamaktadır. Bu kontrolü ise operatörler ayna katlama mekanizmasını görece sessiz bir ortamda çalıştırıp, kapanma ve açılma seslerini değerlendirerek yapmaktadırlar (Şekil 1.1).

Doğal olarak, tam otomatik kontrolün yetersizliği nedeniyle oluşturulan ve daha önce öngörülmeleyen 18 kişilik bir operatör kadrosu ürünün karlılığını düşürmektedir. Diğer yandan, operatörlerin tüm hataları %100 yakaladığından da bahsedilemez.

Bu çalışma kapsamında kullanılmasına karar verilen Yapay Sinir Ağı (YSA), insan beyin hücrelerinin sayısal olarak taklit edilmesi yolu ile sınıflandırma ve fonksiyonel kestirim gibi alanlarda son derece başarılı sonuçlar elde etmektedirler. Öyle ki bazı alanlarda insandan daha iyi sonuçlar almışlardır. Çalışmanın amacı, oluşturulacak bir YSA destekli ses kalite kontrol sisteminin, parametrik (ör. zirve değeri, zirve sayısı, ses yüksekliği gibi önceden belirlenmiş bazı parametreler için oluşturulan eşik değerlerin aşılmasına yönelik algılama sistemi) ses kalite kontrol sistemine ve operatör performans seviyesine göre karşılaştırmasının yapılması olarak belirlenmiştir.

Üretilen ve testi yapılan tüm ürünlerin ses kayıtları yıl-ay-gün-saat-dakika-saniye-sıra no formatında kaydedilebilmekte ve tüm kayıtlara da sonradan erişilebilmektedir. Bir YSA'nın uygulamaya alınmasını anlamlı kılacak en önemli üç ölçüt (yeterli eğitim verisi, istatistiksel dağılım, sınıflandırılabilir bir örüntü) de var olduğu için uygulamada en doğru sonuçlara ulaşabileceği öngörülmüştür.



Şekil 1.1.Uygulama konusu üretim akışı

1.2.Kullanılan Metodoloji

Bu tez çalışmasında, bir ses kalitesi test yöntemi geliştirilerek, ses dosyalarının ön işleminin yapılması; öznitelik üretme ile uygun girdilerin belirlenmesi; modelleme, eğitim, geçerlik denetimi ve doğruluk testleri içeren bir sınıflandırma YSA kullanılmıştır. Ses kalitesinin beklenti seviyesi müşteriye bağlı olduğu için YSA, denetimli (supervised) olarak tasarlanmıştır. Değerlendirmeye alınan ses dosyaları bir uzman tarafından değerlendirilmiş, kalite kontrol sonuçları ile karşılaştırıldıktan sonra etiketlenmiştir. Bu etiketlemeler tüm çalışmanın sonucunu ve etkinliğini doğrudan etkileyebileceği eğitim ve test verilerinin tamamı ikinci bir kontrolden geçmiştir.

Çalışma düşük maliyetlidir ve yöntem olarak benzer ses kalite problemlerine uygulanabilirliği nedeni ile geniş uygulama alanlarına erişme potansiyeli bulunmaktadır. Otomotiv endüstrisinin ses için geliştirdiği niceliksel kalite karakteristikleri kullanılmamış olup, daha genelleştirilebilir ve farklı alanlarda uygulanabilir bir akış tercih edilmiştir.

1.3.Tezin Organizasyonu

Tez dört ana bölümden oluşmaktadır. Kaynak araştırması bölümünde seçilen konunun temelleri ve benzer özellikleri olan problemler üzerine yapılan çalışmalar ve çözüm

metotları irdelenmiş ve özetler halinde sunulmuştur. Takip eden Materyal ve Yöntem bölümünde, detayları ile problem ve hedefler tanımlandıktan sonra çözüme temel oluşturacak olan yöntemler genel kapsamları ile tanıtılmıştır. Ortamdaki ses basınç seviyesi değişimlerinin mikrofonlarla analog elektrik sinyali ve sayısal ortama dönüştürülmeleri, benzer uygulamalarda kullanılan öznitelikler, öznitelik seçme yöntemi, Yapay Sinir Ağı kullanım alanları, türleri ve eğitim algoritmaları açıklanmıştır. Bulgular ve Tartışma bölümünde uygulamada kullanılan veriler ve elde edilen sonuçlar ortaya konmuş ve analiz edilmiştir.

Tez çalışması sonucunda üzerinde çalışılan belirli ses kalite probleminin çözümüne dair faydalı bir YSA ama daha önemlisi benzer problemlere uygulanabilecek bir yol haritası ya da uygulanacak yöntemler bütünü ortaya çıkmıştır. Ekler bölümünde benzer bir ses kalite kontrol sistemi oluşturmak için atılması gereken adımların, elde edilen tecrübeler ve öğrenilmiş derslerden yola çıkılarak özetlendiği önerilen bir akış diyagramı sunulmuştur.

2. KAYNAK ARAŞTIRMASI

Kalite kontrol daha çok bu amaçla geliştirilmiş özel makineler tarafından izleme ve teşhise dayalı olarak yapılmaktadır (Zhang, Huang, 1995). Farklı değişkenlerin sınır değerlerini izlemek ve operatörleri uyarmak, en basit yöntem olmakla birlikte bütün görünmeyen bilginin otomatize edilmiş bir şekilde dikkate alınması ile birlikte ürün kalitesi anlamlı olarak iyileştirilebilir (Isermann, 2006).

Ses ve titreşim verisi kullanılarak üretim ekipman hatalarının tahmini (Emel, Kannatey-Asibu, 1989) ve kalite kontrolde Yapay Sinir Ağlarının kullanılması (Kaya, Oktay, Engin, 2005) iyi bilinen süreçlerdir. Geçtiğimiz on yıllarda, ses dalgalarının yapay sinir ağları ile sınıflandırılması kabul edilebilir bir başarı oranına ulaşmıştır (Dhanalakshmi, Palanivel, Ramalingam, 2009).

İnsanın işitme algılama sistemi ses karakterinin tanımlanmasında elektronik sistemlere göre daha üstündür. Biraz yakından baktığımızda insan kulağının üç bölümden oluştuğunu söyleyebiliriz; dış, orta ve iç kulak. Ses titreşimleri dış kulak ve duyma borusu yolu ile kulak zarına ulaşır. Kulak zarı bu dalgaları orta kulaktaki kemiklere iletir. Kulak kemikleri basıncı artırıp hareketi yavaşlatarak titreşimi oval pencereye iletir. Bu yuvarlak pencere kulak salyangozuna (Cochlea) bağlıdır. Salyangoz ses titreşimlerinin elektrik sinyallerine dönüştürüldüğü içi sıvı dolu bir bölümdür. Taban zarı boyunca 30.000 tüy (sinirsel alıcılar) sıvı içine aktarılan ses titreşimlerinin yarattığı dalga hareketini sinirsel atımlara dönüştürür. Taban zarının her bir alanı farklı bir frekansa duyarlıdır. İnsan kulağı 20 Hz ila 20.000 Hz arasındaki frekansları duyabilir. Ancak 2.000 ila 4.000 Hz arasındaki frekanslara özellikle duyarlıdır. (Sarti, 2017) (Mathews, 1999).

Bir insan ses kaynağını üç boyutta kolaylıkla bulabilir. Her iki kulağa gelen seslerin varış zamanları ve yükseklik farkları ile kafa ve omuzların yapısı sayesinde yön odaklı bir filtreleme gerçekleşmektedir. Filtreleme ses dalgasının yayılımı ile sonuca zayıflama, yansıtma, sapma ve tınlaşım yolları ile ulaşmaktadır. İnsanlar arka plan gürültüsü arasında istedikleri sese odaklanabilmektedirler. İki kulak yerine konacak iki mikrofon ile kulağın işlevi taklit edilememektedir. İnsanın duyma sisteminde öylesine karmaşık

sinyal işleme yapılmaktadır ki ses sinyalinin zamansal ve spektral yapısı ile yükseklik dağılımı çok iyi yakalanmaktadır. Dinleyici ses olayı hakkında geniş ve bütüncül bir izlenme sahip olmaktadır (Sarti, 2017). İnsan performansına erişmek için sesin fiziksel özellikleri ile insan duyarlılığını bağlayacak psiko-akustik parametreler geliştirilmiştir. Bu parametreler ses yüksekliği, keskinlik, pürüzlülük, renk uyumudur. Örneğin renk uyumu tekil ses tonlarının pek çok ses tonu içerisindeki oranını ifade eder (Sarti, 2017). Sıklıkla yüksek tonlama “hoşa gitmeyen ses” izlenimi verir. 1KHz frekanstaki 60 dB’lik bir sinüs dalgası 1 Tu değerindedir (Elliott, 2010).

Yapay sinir ağları ile ses ve resim tanıma konusunda yapılan LifeCLEF 2018 araştırmasına göre insan uzmanlar hala Evrimsel Yapay Sinir Ağlarından (CNN) daha başarılıdır. Buna göre resimden yaşayan organizmaların tanımlanmasında (PlantCLEF) CNN başarı oranı %85 ‘i aşmaktadır. Aynı çalışmada çıkardıkları seslerden kuşları ayırt etmeyi hedefleyen BirdCLEF yarışmasında başarı oranı %80’ i aşmıştır (Joly, vd., 2018).

Otomotiv sanayinde sübjektif ses kalitesi konusunda hassasiyet daha da artmaktadır. Elektrikli araçlar ile birlikte araçların sessizleşmesi önceden kabul edilebilir ses seviyelerinin tekrar değerlendirilmesine yol açmıştır. Örneğin 2019 yılında VW mühendislik belirtilerinde ayna katlama mekanizmaları için “hoşa gitmeyen ses“ sübjektif tanımı istenmeyen ve tedarikçinin sorumluluğuna verilen bir ölçüt olarak yer almıştır. Pencere hareketini sağlayan mekanizmalarla yapılan bir çalışmada ses değerlemesinde objektif ve sübjektif kriterlerin korelasyonu incelenmiş ve sübjektif can sıkıcı ses değerlendirmesinin hem ses yüksekliği (Loudness) hem de keskinlik (Sharpness) ile korelasyon içinde olduğu ortaya konmuştur. Bunun yanında SPL (Sound Pressure Level) ölçümlerinden ortalama ve rms değerleri ile de anlamlı korelasyon bulunmuştur (Vollandri, vd., 2018).

Sottek ve Henrique (2020) şimdiye kadar kullanılan akustik/psikoakustik parametrelerin genellikle tipik olarak lineer kombinasyon ile kullanıldığını ve insan algısını daha iyi bir biçimde tanımlamaya yardımcı olacak pek çok lineer olmayan karmaşık döngünün

gözardı edildiğini belirtmektedirler. Çalışmalarında spectro-temporal modeller ve makine öğrenmesi yöntemleri ile yeni bir metrik önermişlerdir.

Otomotiv sanayiinde “hoşa gitmeyen ses” önemli bir son kullanıcı kriteri olduğu için NVH (Noise/Vibration/Harshness) uzmanlık alanında çalışan mühendisler ve akademisyenler bu konuda detaylı araştırmalar yapmaktadırlar (Elliott, 2010).

Psiko-akustik parametreleri kullanarak geliştirilen objektif kalite kontrol yöntemleri bulunmaktadır (Wang, Subic, 2011). Aynı kaynakta, 30 adet örnek ayna katlama mekanizması üzerinden yaptıkları çalışmada uygun (OK) olarak değerlendirilen parçalar üzerinden belirlenen eşik değerini kullanarak %100 başarı elde ettiklerini raporlamışlardır. Ancak yapılan çalışma geliştirilebilmekten uzak, konuya özel formüle edilmiştir. Sübjektif “kabul edilebilir” ayna katlama mekanizması psiko-akustik ses değerleri sadece bir örnek üzerinden alınıp hesaplanmakta ve referans veri olarak kullanılmaktadır. Çalışma seri üretim şartlarında yapılmamış olup, yeni bir yöntem önermekle birlikte her yeni ürüne özel modelleme gerektirmektedir. Hesaplanan eşitliliklerdeki katsayılar geliştirilebilir değerler olmaktan uzak daha çok ilgili ürün ve üretim sürecinden gelen değerlerdir.

Görüldüğü kadarı ile Wang ve Subic (2011) haricinde katlanabilir ayna ses kalite kontrolü bugüne kadar çalışılmamıştır. Onlar da son kullanıcı gözü ile değerlendirmişlerdir. Bu çalışma üretici tarafından kalite kontrol fonksiyonunu yerine getirilmesi ve verimliliğin artırılması ile ilgilidir.


3. MATERYAL ve YÖNTEM

3.1.Problemin Tanımlanması

Bu tez konusu kalite kontrol problemi, tam otomatik çalışan bir seri üretim hattında ortaya çıkmaktadır. Bir konveyör üzerinde akan paletler her bir istasyonda durmakta ve robot kol ya da mekanizma ile alt parça montajı yapılmakta, ilgili operasyonun sonucu yine otomatik olarak kontrol edildikten sonra ürün bir sonraki istasyona geçmektedir. Montajı tamamlanan ürün elektrik ve fonksiyon testlerine girmekte ve en son ses kalitesi kontrol edilmektedir. Ses kalitesine göre uygun olmayan parçalar hata türüne göre hat sonunda hattın otomatik alınıp, ilgili hata tipi kutusu içerisine gönderilmektedir

Mevcut sistemde hata tipleri; Osilasyon (D1), Starting (D2), Click Click (D3) ,High (D4) sesleri olarak isimlendirilmiştir. “Osilasyon” hatası parçanın açma kapama süresi boyunca sesin hoşça gitmeyecek şekilde periyodik olmayan alçalma ve yükselmesi olarak tanımlanabilir. “Starting” başlangıçta parçalar arasındaki fazla boşluktan gelen ilk çarpma sesi olarak tanımlanmaktadır. “High” parça çalışma sırasında aşırı zorlanıyor hissiyatı veren ve kulağı rahatsız eden ses olarak tanımlanabilir. Bu rahatsızlık veren ses çalışma süresinin tamamında değil küçük bir kısmında da oluşabilmektedir. “Click Click” sesi çalışma sırasında rastgele periyodlarda “klik” sesinin iki-üç kere üst üste duyulmasıdır. “Osilasyon” hatası çok miktarda çıkarken Starting gibi bazı hatalar çok nadir çıkmaktadır, Ses hataları aynı ayna katlama mekanizmasında birden fazla olabilmektedir. Hem D3 hem D4 olan mekanizma bulunduğu hangi hata kutusuna atılacağına büyük bir önemi yoktur. Sonuçta hataların incelenmesi ve raporlanması, parçanın geri dönüşümü aynı yolla yapılmaktadır. Bu tür durumlarda beklenen hangi hata tipi ağırlıklıysa o gruba ayrılmasıdır.

Şekil 3.1, üretim hattında belirli bir zaman kesitinde toplanan verileri göstermektedir. Buna göre otomatik kalite kontrol sisteminden ürün %60 oranında OK çıkmakta; geriye kalan üretim %22 Osilasyon, %1 Starting, %7 Click Click, %10 High sınıflandırmalarıyla hatalı olarak ayrılmaktadır.



Şekil 3.1. Üretim ve İkinci Kontrol Sonrası Hata Oranları

Aynı ürünlere insan operatörler tarafından yapılan kontroller sonucunda makinenin OK olarak ayırdığı %60 'lık kısmın nominal %2'si hatalı olarak ayrılmakta; %58'lik kısmın OK olduğu teyid edilmektedir. Dramatik kısım ise izleyen kontrollerdedir. Osilasyon Hatalı olarak ayrılan %22 oranındaki ürün %20 OK iken, %2 hatalı olarak sınıflandırılmaktadır. Starting hatalı %1'lik ürünün yarısı, nominalde %0,5'lik kısmı OK olarak etiketlenmekte %0,5'lik kısım ise teyid edilmektedir. Click Click hatalı ayrılan %7'lik kısım insan kontrollerinde nominal %6,5 OK olarak ayrılmakta ve sadece %0,5'i hatalı olarak ayrılmaktadır. Benzer şekilde High hatalı ayrılan %10'luk üretimde hata oranı %2'ye düşmekte ve %8'i OK olarak dönüştürülmektedir.

Bu tür Tip 1 ve Tip 2 olarak sınıflandırılabilir hatalı sınıflandırmaları görmek ve performans ölçütü oluşturmak için Karışıklık Tabloları kullanılmaktadır. Şekil 3.2'de yukarıda verilen parametrik sistem için oluşturulan Karışıklık Tablosu görülmektedir.

		KONTROL SONUCU		
		OK	NOK	
GERÇEK	OK	58	35	93
	NOK	2	5	7
		60	40	100

Şekil 3.2. Parametrik sistemin karışıklık tablosu

Ses kalitesine göre sınıflandırma yapan program bazı parametrelerin eşik değerlerini kriter olarak almakta ve bu değerleri geçen parçaları hata türlerine göre ayıklamaktadır.

Daima iki tür hata oluşmaktadır:

- a. Uygun olmayan (NOK) parçaların Uygun (OK) olarak etiketlenmesi (Tip 1) : Olası maliyetler kalite şartları, hat duruş şartları, garanti maliyetleri, iş kaybı olarak sayılabilecek ve şirketin itibar kaybına yol açabilecek hata türüdür. Bu tür hataların mutlaka engellenmesi için eşik değerler ayarlanmıştır. Yine de %2 civarında Tip 1 hata oluşmaktadır.
- b. Uygun (OK) parçaların Uygun olmayan (NOK) olarak etiketlenmesi (Tip 2) : İnsan ile kalite kontrolün yapıldığı ikinci bir kalite duvarı maliyeti, müşteriye hızlandırılmış sevkiyat maliyetleri bu hatanın sonucu olarak ortaya çıkmaktadır. Tip 1 hatayı en azaltmak için artırılan eşik değerler bu tür hataları %40'lar seviyesine getirmiştir.

Performans ölçümü için Duyarlılık (Sensitivity), Kesinlik (Specificity) ve Doğruluk (Accuracy) ölçütleri kullanılacaktır. Tanımlar aşağıda verilmiştir:

Uygun parçanın belirlenme doğruluğu olarak Duyarlılık ifadesi :

$$D_r = \frac{D_D}{D_D + D_Y} \quad (2.1)$$

D_r Duyarlılık oranı

D_D Doğru olarak tahmin edilen OK parça sayısı

D_Y Yanlış olarak tahmin edilen OK parça sayısı (Tip 2 HATA)

Hatalı parçanın belirlenme doğruluğu olarak Kesinlik (S) ifadesi :

$$S_r = \frac{S_D}{S_D + S_Y} \quad (2.2)$$

S_r Kesinlik oranı

S_D Doğru olarak tahmin edilen NOK parça sayısı

S_Y Yanlış olarak tahmin edilen NOK parça sayısı (Tip1 HATA)

Genel olarak hataların belirlenme doğruluğu olarak tanımlayabileceğimiz Doğruluk (A) aşağıdaki şekilde formüle edilebilir:

$$A_r = \frac{S_D + D_D}{S_D + S_Y + D_D + D_Y} \quad (2.3)$$

A_r Doğruluk oranı

Şekil 3.2’de verilen Karışıklık Tablosu kullanılarak parametrik sistem için Duyarlılık (2.1) ifadesi ;

$$D_r = \frac{D_D}{D_D + D_Y} = \frac{58}{58 + 35} = \%62$$

Kesinlik (2.2) ;

$$S_r = \frac{S_D}{S_D + S_Y} = \frac{5}{5 + 2} = \%71$$

Doğruluk (2.3) ;


$$A_r = \frac{S_D + D_D}{S_D + S_Y + D_D + D_Y} = \frac{5 + 58}{5 + 2 + 58 + 35} = \%63$$

olarak hesaplanabilir.

Bu çalışmada, yukarıdaki ölçütlere göre çalışan mevcut parametrik ses kalitesi belirleme yazılımından daha iyi performans gösteren bir sistem oluşturulması hedeflenmiştir. İnsan uzmanların şirket içinde hedeflenen “Doğruluk” oranı %95 alınarak, denklik durumu da incelenecektir. Şu anki parametrik ses kalitesi belirleme yazılımının performans göstergeleri Duyarlılık %62, Kesinlik %71 ve Doğruluk %63 olarak hesaplanmıştır.

3.2. Ayna Katlama Mekanizması Tasarımı :

Ayna katlama mekanizmaları, araç (otomobil) yan aynalarının içerisine yerleştirilmiş ve konfor, kolaylık veya güvenlik gibi nedenlerle aynaların uzaktan kontrolünü sağlayan sistemlerdir. Yan aynalar genellikle aracın her iki tarafına sürücünün rahatlıkla görebileceği yerlerde konumlandırılmaktadır, ancak özellikle dar alanlara park etmek gerektiğinde, park esnasında hareketli başka nesnelere çarpmasına karşı aynayı koruma amacıyla kapanması istenmektedir. Bu korumayı da ayna normal açık konumundan cam tarafına doğru içeri doğru kapanarak sağlamaktadır. Önemli olan bu açma kapanma sırasında son kullanıcıları rahatsız edecek ses veya titreşim olmamasıdır. Son model arabalarda bu özellik giderek artan bir oranda bulunmaktadır



Şekil 3.3: Ayna katlama mekanizması ve aynadaki yeri (Wang, Subic, 2011)

Ürün; plastik bir dış çerçeve içerisine oturtulmuş bir doğru akım elektrik motoru, bir çinko alaşım malzemedeki iç-dış dişli (ring gear), bir plastik dişli, bir başka hareket yönü değiştirici bronz sonsuz dişli (worm), dişlileri üzerinde taşıyan 14 çelik bilye içeren plastik parçadan oluşmaktadır.

Ses kaynağı olarak elektrikli motorun çalışma sesi, dişliler arasındaki tolerans farklarından gelen boşluk, ilgili alt parçaların üretim süreçlerinden gelen ölçüsel farklar, dönen bilyelerin yüzey kalitesi sayılabilir. Örnek boşluk payı tolerans analizi Çizelge 3.1’de verilmiştir.

Çizelge 3.1. Ayna Katlama Mekanizması elemanları tolerans analizi (mm)

PARÇA	NOMİNAL	TOLERANS		TOPLAM	
		+	-	+	-
HOUSING	20,58	0,04	-0,04	20,62	20,54
WORM	18,63	0	-0,05	18,63	18,58
SLEEVE	0,90	0,05	-0,05	0,95	0,85
TOPLAM FARK	0,15	0,19	-0,14	0,34	0,01

3.3. Ses Kalite Problemleri :

Mekanizmanın çalışması sırasında ortaya çıkan ses kaçınılmaz bir olgudur. Ancak sıra dışı ve “hoşa gitmeyen” sesler kalite problemi olarak değerlendirilmektedir. Bu tür sesler mekanizmanın çalışmaya ilk başladığı anda, kapanma ve açılma hareketi sırasında ortaya çıkabilir. Ses problemleri montaj hattı sonunda dört ana grupta sınıflandırılmaktadır. Birden fazla hata tipi ortaya çıktığında son olarak ortaya çıkan hata tipine göre sınıflandırma yapıp mekanizma otomatik olarak ayrılmaktadır.

Çizelge 3.2. Ses kalite problemleri ve muhtemel nedenleri

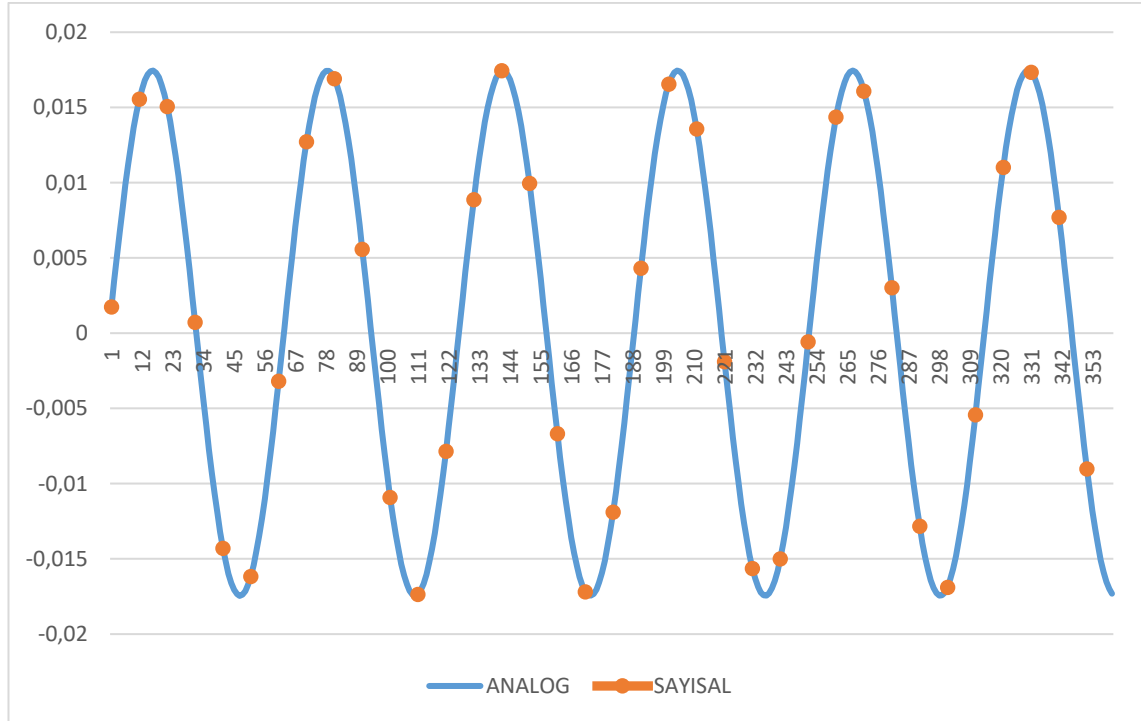
	HATA	OLASI NEDENİ
D1	Osilasyon (Alçalıp yükselen ses)	Hız farkları, boşluklar
D2	Starting (Başlangıç sesi)	Boşluk (Free Play)
D3	Click Click (Çevrimsel tikler)	Çark dişlilerindeki kusurlar, bilye yüzeylerindeki kusurlar
D4	High (Yüksek ses + Tırlama)	Çark dişlilerinin tam uyuşmaması

3.4. Ses Sinyallerinin İşlenmesi

Sinyal, zaman gibi bağımsız bir değişkene bağlı fonksiyonel bir değişimi gösterir. Ses sinyali hava basıncının zamana göre bir fonksiyonu olup, bir mikrofon yardımı ile hava basıncındaki değişimler algılanarak elektriksel sinyale dönüştürülebilmektedir.

Bir ses sinyalinin işlenmesi onun matematiksel olarak ifade edilerek, dönüştürülmesine karşılık gelir. Analog bir sinyali zamana göre değişen sürekli bir $y(t)$ fonksiyonu ile gösterebiliriz. Eğer bu sinyali T örnekleme periyodu ile örneklersek ($t = nT$) sayısal sinyal olan $y[n] = y[nT]$ kesikli zaman sinyali elde edilebilir. Örnekleme oranı $f_s = \frac{1}{T}$ şeklinde ifade edilir.

Şekil 3.4'te Analog ve sayısal ses sinyalleri arasındaki ilişki görülebilir. Gösterim kolaylığı açısından bundan sonraki şekillerde sayısal değerlerden oluşan ses sinyalleri interpolate edilerek analog gibi gösterilecektir.



Şekil 3.4: Bir analog sinyal ile örneklenmiş sayısal karşılığı

3.5.Öznitelik Üretimi

Girdileri oluşturacak karakteristik ses özellikleri için zaman ve frekans uzayında çeşitli yaklaşımlar geliştirilmiştir. Sesin hem zaman uzayından elde edilen özniteliklerine, hem de frekans uzayından elde edilen özniteliklerine ek olarak hem zaman hem de frekans uzaylarını birlikte içeren özniteliklerine de yer verilmiştir. Hangi özniteliklerin sorunun çözümüne katkıda bulunabileceği bilinmediği için başlangıçta mümkün olduğunca geniş bir şekilde literatürde yer alan öznitelikler bu bölümde verilmiştir.

3.5.1. Zaman Uzayı Temel Öznitelikleri

Zaman uzayı öznitelikleri, ses sinyalinin algılanan hava basınç değerlerinin (ses algılayan mikrofonun diyaframındaki yer değiştime miktarının) tepe ve dip noktaları ve bunların sayısı ile standart sapma, karelerin köklerinin toplamı gibi enerji dağılımını takip eden özniteliklerdir.

Zaman Ağırlıklı Ses Seviyesi Farkları: Zaman ağırlıklı ses seviyesi L_t , zaman ağırlıklı ses seviyelerinin RMS değerinin referans ses seviyesine oranlanıp, dB'e dönüştürülmesi olarak tanımlanmıştır (Harris, Tocci, 1993). Buna göre,

$$L_t = 10 \log_{10} \left\{ \frac{\left(\frac{1}{\tau} \int_{t_s}^t y(\xi)^2 e^{-\frac{t-\xi}{\tau}} d\xi \right)}{P_0^2} \right\}$$
$$L_t = 10 \log_{10} \left\{ \frac{h(y^2)}{P_0^2} \right\}$$

$h(y^2)$, y^2 'nin etki yanıtı $(1/\tau)e^{-\frac{1}{\tau}}$ olan bir filtreye karşılık gelmektedir. Burada y filtrenin zaman uzayı çıktısı olup, frekans uzayında filtrenin etki yanıtı $H(s) = \frac{1}{s + \frac{1}{\tau}}$ şeklinde düşük-geçirgen niteliğe sahiptir. Aynı filtrenin kesikli zaman yanıtı ise aşağıda verilmiştir.

$$H(z) = \frac{1/(\tau \times f_s)}{1 - (e^{-1/(\tau \times f_s)})z^{-1}}$$

τ zaman ağırlıklandırma katsayısı olup, sinyal değişiminin hızlı takibi (Fast) için $\tau = 0.125$, yavaş takibi (Slow) için $\tau = 1$ değerini almaktadır. f_s ses basıncının örnekleme oranıdır. ξ ise okunan ses basınç değeridir.

Ayna mekanizmasının Kapanma (DtP) ve Açılma (PtD) sesleri arasındaki ses yükseklik farkları subjektif ses kalitesini belirleyebileceği için en yüksek ve ortalama ses seviyeleri arasındaki farklar ilk iki öznelik olarak belirlenmiştir. Öngörülen hedef bu iki ses seviyesi arasında %15'ten fazla fark olmamasıdır.

$$\Delta_{MAX} = |Max_{DtP}(L_t) - Max_{PtD}(L_t)| \quad (3.1)$$

$$\Delta_{AVG} = |Avg_{DtP}(L_t) - Avg_{PtD}(L_t)| \quad (3.2)$$

Literatürde pek çok ses analizi ve sinyal işleme yöntemi bulunmaktadır (Zhang, Huang, 1995). Zaman uzayı ile ilgili olarak kullanılmış diğer öznelikler bu çalışmaya eklenmiştir (Jin, vd., 2014). Aşağıdaki ifadelerde x veri seti, x_i veri setinin i . elemanı, \bar{x} beklenen değer, N veri setinin eleman sayısı olmak üzere:

Standart Sapma

$$x_{std} = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}} \quad (3.3)$$

Peak

$$x_p = \max(|x_i|) \quad (3.4)$$

Skewness

$$x_{skw} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{x_{std}^3} \quad (3.5)$$

Kurtosis

$$x_{kurtosis} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{x_{std}^4} \quad (3.6)$$

Squared Mean Root

$$x_{smr} = \left(\frac{1}{N} \sum_{j=1}^N \sqrt{|x_j|} \right)^2 \quad (3.7)$$

Root Mean Squared

$$x_{rms} = \sqrt{\sum_{i=1}^N \frac{x_i^2}{N}} \quad (3.8)$$

Crest Factor:

$$CrF = \frac{x_p}{x_{rms}} \quad (3.9)$$

Clearance Factor

$$CF = \frac{x_p}{x_{smr}} \quad (3.10)$$

Shape Factor

$$SF = \frac{x_{rms}}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (3.11)$$

Impact Factor

$$IPF = \frac{x_p}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (3.12)$$

Zaman uzayında yüksek değerler ile bunların sayıları ses bant genişliğine oranla anlamlı olabilir. Aşağıdaki formüller analiz için ayrıca eklenmiştir:

Minimum Power: Eksi sonsuz hariç en düşük logaritmik değer

$$L_{min} = \min[10 * \log_{10}(x_i - x_{min})], \quad x_{min} \geq -\infty \quad (3.13)$$

Number of Peaks (P) : Anlamlı derecede yüksek ses basınç değerlerinin sayısı

$$P = say \left[x_i > \left(\bar{x} + \frac{x_{max} - \bar{x}}{2} \right) \right] \quad (3.14)$$

Burada veri aralığının en üst %25'lik bandı “anlamlı” olarak tanımlanmıştır.

3.5.2. Kesikli Fourier Dönüşümü (DFT)

Hava içinde yayılan ses dalgaları kendileri ile birlikte yüksek miktarda enerji taşırlar. Sinuzoidal salınım yapan bir dalganın frekansı bir saniyede yaptığı 2π radyan salınım sayısı ile ölçülür ve birimi Hertz (Hz)'dir. Herhangi bir sinyal aslında sinüzoidal harmoniklerin bir bileşkesi olarak ifade edilebilir. Herhangi bir fonksiyonun Fourier Serisine açılımını esas alan bu dönüşüm aynı zamanda zaman uzayından frekans uzayına dönüşümü tanımlar. Zamana bağlı $y(t)$ gibi bir sürekli fonksiyon için Fourier dönüşümü

$$y(i\omega) = \mathcal{F}\{y(t)\} = \int_{-\infty}^{\infty} y(t)e^{-i\omega t} dt$$

şeklinde verilir (Isermann, 2006). Görüleceği üzere zaman (t) uzayındaki bir sinyal frekans (ω) uzayında tanımlanmıştır. Dijital sinyal örnekleme sistemlerinde ayırık zamanlarda sınırlı sayıda örnekleme yapıldığı için Kesikli Fourier Dönüşümü (DFT) kullanılacaktır. Frekans uzayında kullanılabilecek öznelilikler izleyen bölümde özetlenmiştir.

Kesikli Fourier Dönüşümü ses dalgasının sonsuz sayıda sinüsoidal dalgadan oluştuğunu varsayıp, her bir sinüzoidal bileşen için frekans ve genlik değeri belirleyerek dönüşümü sağlar. Böylece karmaşık sinyali oluşturan sinüzoidal dalgalar ayrıştırılarak zaman uzayından frekans uzayına geçiş yapılır.

Ancak DFT dönüşümünün detayına girmeden önce frekans çözünürlüğü ve “sızıntı” probleminde değinmek gerekir. Örnekleme oranı f_s ve eldeki ölçüm noktası sayısı n olduğunda Nyquist teoremi (Lüke, 1999) dönüşüm sonrası elde edilebilecek en yüksek frekans değerini $\frac{f_s}{2}$ olarak tanımlar. Frekans çözünürlüğü de


$$\Delta f = \frac{f_s}{n}$$

olarak tanımlanır. Bir zaman sinyalinin frekans içeriğini bulmak için belirli uzunlukta örneklenmiş veri gerekir. Varsayalım ki frekans çözünürlüğünü artırmak için ölçüm süresini artırdık. Aşağıdaki kuraldan dolayı bu çözünürlüğü azalttığımız anlamına gelir.

$$\Delta t \times \Delta f = \text{Sabit}$$

Örnekleme oranını artırmak da durumu iyileştirmeyecektir; çünkü bu sadece üst frekans limitini artırır (Nyquist limit).

DFT sinüzoidal dalgaların sonsuz olduğunu varsayar ve frekansları bu duruma göre hesaplar. Gerçekte ses kayıtları daima sınırlı sürelidir. Özellikle başlangıç ve bitiş bölümleri bu varsayıma uymaz ve frekans hesaplaması ‘sızıntı’ olarak nitelenen ‘spektral hata’ verir. Şekil 3.5’te verilen frekans spektrumunda temel modun saçakları şeklinde ortaya çıkan bir sızıntı örneği gösterilmiştir.



Şekil 3.5 Fourier Dönüşümü sonrası ortaya çıkan spektral sızıntı hatası


Bu hatayı azaltmak için FFT dönüşümü öncesi örneklenmiş sinyale pencere uygulanır. Pencere çeşitlidir ve duruma göre tercih edilebilir. Verinin elde edildiği sistemin donanımlarının üreticisi olan National Instruments internet sitesinde Çizelge 3.3.teki çizelge verilmektedir.

Bir pencere tipi standart olarak tavsiye edilmemekle birlikte Hanning pencere tipinin uygulanan durumların %95'inde olumlu sonuç verdiği ancak, aslında sinyale uygulanabilecek her tip pencere için hata oranlarının hesaplanarak en uygun pencerenin seçilmesi gerektiği belirtilmektedir.

Çizelge 3.3. Pencere tipleri ve tercih edilebilirlik durumları

Sinyal İçeriği	Uygun Pencere
Sinüs dalgası vey sinüs dalgaları kombinasyonu	Hann
Sinüs dalgası (büyüklük doğruluğu önemli)	Flat Top
Darband rastgele sinyal (titreşim verisi)	Hann
Geniş band rastgele (beyaz gürültü)	Uniform
Çok yakın sinüs dalgaları	Uniform, Hamming
Heyecan verici sinyaller (Çekiç vuruşu)	Force
Yanıt sinyalleri	Exponansiyel
Bilinmeyen içerik	Hann
Yakın frekansta ama farklı büyüklükte iki tone	Kaiser-Bessel
Yakın frekans ve büyüklükte hemen hemen aynı	Uniform
Doğru Tek Tone büyüklük ölçümleri	Flat Top

Pencere kullanımının frekanstaki sızıntıyı engellemesinin yanında önemli bilgileri ortadan kaldırabilmesi gibi bir risk de vardır. Özellikle sinyalin başında ve sonunda olan bilgiler kesilmektedir. Bu etkiyi en aza indirmek için “üst üste bindirme” (overlapping) metodu uygulanmaktadır.



Şekil 3.6. Soldaki sinyale uygulanan Hanning Window Uygulaması ile değişen sinyal

Zaman uzayı ölçümleri kesikli olduğu için, frekans uzayına geçişte DFT kullanılacak olup, X ve Y uzunlukları n olan sayı dizileri olsun (Roberts, 2003),

$$Y(k) = \sum_{j=1}^n X(j)W_n^{(j-1)(k-1)}$$

Burada ,

$$W_n = e^{-\frac{2\pi}{n}}$$

DFT dönüşümü 0'dan Nyquist sınıra kadar olan frekanslardaki sinüzoidal bileşenlerin genliklerini (sinyalin frekans bazında gücü) verir. Dönüşüm değerinin mutlak değeri orijinal fonksiyonda bulunan k indisine karşılık gelen frekansta ortogonal bileşenlerin bileşke genliğine eşittir.

$$\|Y(k)\| = \|a_k + b_k i\| = \sqrt{a_k^2 + b_k^2} \quad k = 1, 2 \dots n \quad (3.15)$$

3.5.3. Otokorelasyon (Autocorrelation)

Sinyallerin korelasyonu, basit anlamıyla iki farklı sinyalin benzerlik seviyesini göstermektedir. Bir periyodik sinyalin kendisi ile karşılaştırılması olan otokorelasyon ise sinyalin zaman içindeki gecikmesini verir. Otokorelasyon ses sinyalinin temel frekansını hesaplamak için de kullanılabilir (Shimamura, Kobayashi, 2001), (Stocia, Moses, 2005). Otokorelasyonun orta ve sağa doğru 1 ve 2. tepe değerleri ve tepelerin yerleri karakterisitk bilgi vermektedir. Formül aynı sinyale uygulanırsa iki sinyal arasındaki gecikme hesaplanabilir. Eğer gürültülü bir sinyalin içerisinde anlamlı bir sinyal gizlenmiş ise,

otokorelasyon ile kendisi ve konumu tam olarak tespit edilebilir. Özetle korelasyon şöyle tanımlanabilir (Stocia, Moses, 2005):

$$R_{xy}(m) = E\{x_{n+m}y_n^*\} = E\{x_n y_{n-m}^*\}$$

burada $-\infty < n < +\infty$, * kompleks sayı gösterimi, $E\{\}$ beklenen değer operatörüdür. Sınırlı örneklem için

$$\hat{R}_{xy}(m) = \begin{cases} \sum_{n=0}^{N-m-1} x_{n+m}y_n^* & m \geq 0, \\ \hat{R}_{xy}^*(-m) & m \leq 0 \end{cases}$$

m konumuna bağlı korelasyon çıktı vektörü c , aşağıdaki gibi tanımlanmıştır:

$$c(m) = \hat{R}_{xy}^*(m - N), \quad m = 1, 2, \dots, 2N - 1 \quad (3.16)$$

3.5.4. Ses Seviyesi Ölçümü

Decibel bir oranı ifade etmenin logaritmik yoludur. P_1 ve P_2 ses seviyelerindeki iki farklı kaynağın ses seviye farkı dB cinsinden aşağıdaki formüle göre hesaplanabilir.

$$\Delta P = 10 \log(P_2/P_1)$$

Örneğin ikinci ses birincisinden 2 kat büyükse aralarındaki fark 3 dB, 10 kat fark varsa 10 dB, 1 milyon kat fark varsa 60 dB fark oluşacaktır.

Ses basıncındaki değişimleri elektriksel sinyale dönüştüren bir mikrofon ses basıncı (p) ile orantılı olarak yanıt verir. Bir ses dalgasının gücü, ses basıncının karesi olarak tanımlanır. Bu durumda ses basıncından ses seviyesi farkı hesaplama formülü aşağıdadır.

$$\Delta P = 10 \log(P_2/P_1) = 10 \log(p_2^2/p_1^2) = 20 \log(p_2/p_1)$$

Desibel bir oran olduğuna göre öyle bir referans seçilmelidir ki ses seviyesi ölçümleri herkes tarafından aynı şekilde anlaşılsın. Hava için bu referans değeri $p_{ref} = 20$ mikropascal olarak belirlenmiştir.

Bu çalışmada dB cinsinden ses seviyesi Amerikan Standartlar Enstitüsü ANSI S1.4 Ses Ölçerler Teknik Şartnamesi, 1983 ve Uluslararası Elektroteknik Elektroakustik Komisyonu – Ses Seviye Ölçerleri – Bölüm 1: Teknik Şartnameler. IEC 61672-1:2013'e göre hesaplanmaktadır.

3.5.5. Öznitelik Seçimi:

Öznitelik geliştirmek için pek çok yöntem bulunmaktadır. Bunlardan sadece bazıları sınıflandırma amacına anlamlı bir katkıda bulunur. Oluşturulacak YSA'ya girdi olacak özniteliklerin tüm havuz içinden seçilmesi için pek çok teknik geliştirilmiştir. Bunlardan bazıları arasında “Principal Component Analysis” (PCA), “Linear Discriminant Analysis” (LDA), “Neighbourhood Component Analysis” (NCA) sayılabilir. Bu çalışmada parametre belirleme gereksinimi olmayan NCA kullanılmasına karar verilmiştir.

Komşuluk Bileşen Analizi

Komşuluk Bileşen Analizi (Neighborhood Component Analysis - NCA), sınıflandırma algoritmasının tahmin doğruluğunu maksimize etmeyi amaçlayan, parametrik olmayan bir öznitelik seçme yöntemidir (Yang, Wang, Zuo, 2012). Eğitim verisi üzerinde birini-dışarıda-bırak (Leave One Out - LOO) ortalama kaybını ölçen amaç fonksiyonunu minimize eden öznitelik ağırlıklarının düzenlenmesi ile öznitelik seçme yapılır. Algoritma, verinin dağılımı ile ilgili parametrik varsayımlarda bulunmadan, çoklu sınıflandırma problemleri için uygulanabilir. Gerçek ve yapay veri setleri ile yapılan deneylerde bu algoritmanın oluşturulan sayıca fazla, ancak ilgisiz özniteliklerden olumsuz etkilenmediği ve çoğunlukla sınıfının en iyisi yöntemlerden daha iyi sonuç verdiği gözlenmiştir (Yang ve ark., 2012).

Yöntemin zayıf yanı, çözümü oluşturan sınıflandırma olasılıklarının hesaplanabilmesi için tüm veri seti üzerinden işlem yapılması gerekliliği olup, sonuç olarak hesaplama zaman almaktadır. Ancak yaklaşım gereği, öznitelik seçimi bir kez yapılacağı için hesaplama hızı dikkate alınmamıştır. Yöntemi kısaca özetlemek gerekirse;

$S = \{(x_i, y_i), i = 1, 2, 3, \dots, n\}$ eğitim setinin bir çoklu sınıflandırma problemine ait olduğu varsayalım. Burada, $x_i \in \mathbb{R}^p$ öznitelik vektörleri, $y_i \in \{1, 2, \dots, C\}$ sınıf etiketleri ve C de sınıf sayısıdır.

Amaç, $f : \mathbb{R}^p \rightarrow \{1, 2, \dots, C\}$ x 'in y doğru etiketi için tahmin edecek bir $f(x)$ öznitelik vektörünün bulunmasıdır. Rastgele bir sınıflandırıcı yaklaşımında,

- i. S veri kümesinden rastgele olarak x 'in referans noktası olacak bir $Ref(x)$ seçilir.
- ii. $Ref(x)$ referans noktasının etiketi kullanılarak x 'i etiketlenir.

Komşuluk Bileşen Analizinde referans noktası rastgele seçilir ve diğer tüm noktaların S içinden seçilme olasılıkları bu referans noktasına göre hesaplanır. Eğer x_j 'nin d_w fonksiyonu ile belirlenen mesafesi x 'e daha yakınsa S içerisinde referans noktası olarak seçilmesi olasılığı $P(Ref(x) = x_j | S)$ daha yüksektir. Burada w_r öznitelik ağırlıkları olmak üzere,

$$d_w(x_i, x_j) = \sum_{r=1}^p w_r^2 |x_{ir} - x_{jr}|$$

k 'nın $d_w(x_i, x_j)$ küçük olduğunda büyük sayıları veren bir kernel fonksiyonu olduğunu varsayalım. Yang et al. (2012)'de önerildiği gibi Gauss tipi $k(z) = e^{-\frac{z}{\sigma}}$ olsun. Tüm noktaların seçilebilme olasılıklarının toplamı 1 olacağından,

$$P(Ref(x) = x_j | S) = \frac{k(d_w(x, x_j))}{\sum_{j=1}^n k(d_w(x, x_j))}$$

yazılabilir. S eğitim setinden (x_i, y_i) noktası hariç tutulduğunda S^{-i} verisini kullanarak x_i nin etiketini rastgele birini dışarıda bırak algoritması ile tahmin ettiğimizi düşünelim. Referans noktası x_i olduğunda x_j noktasının seçilme olasılığı (p_{ij})

$$p_{ij} = P(\text{Ref}(x_i) = x_j | S^{-i}) = \frac{k(d_w(x, x_j))}{\sum_{j=1, j \neq i}^n k(d_w(x, x_j))}$$

olur.

Doğru sınıflandırma yapan ortalama birini-dışarıda-bırak olasılığı, sınıflandırıcının i . gözlemden S^{-i} kümesini kullanarak yapacağı doğru sınıflandırma olasılığı olan p_i 'ye eşittir.

$$p_i = \sum_{j=1, j \neq i}^n P(\text{Ref}(x) = x_j | S^{-i}) \cdot I(y_i = y_j) = \sum_{j=1, j \neq i}^n p_{ij} y_{ij}$$

yazılabilir. Burada $y_{ij} = I(y_i = y_j) = \begin{cases} 1 & y_i = y_j \text{ ise} \\ 0 & \text{diğer} \end{cases}$ 'dir. Böylece, amaç fonksiyonu

$$F(w) = \frac{1}{n} \sum_{i=1}^n p_i$$

olur. Eşitliğin sağ tarafı ağırlık faktörü w 'ya bağlıdır. Komşuluk Bileşen Analizinin amacı w 'ya göre $F(w)$ değerini maksimize etmektir. Yang et al. (2012)'de önerilen λ parametresini içeren amaç fonksiyonu kullanılacak olursa.

$$F(w) = \frac{1}{n} \sum_{i=1}^n p_i - \lambda \sum_{r=1}^p w_r^2 = \frac{1}{n} \sum_{i=1}^n \sum_{j=1, j \neq i}^n p_{ij} y_{ij} - \lambda \sum_{r=1}^p w_r^2 = \frac{1}{n} \sum_{i=1}^n F_i(w)$$

Burada λ düzeltme parametresidir. p_{ij} 'deki σ parametresini 1 seçtikten sonra ağırlık vektörü w herhangi bir λ değeri için aşağıdaki gibi ifade edilebilir. ($f(w) = -F(w)$; $f_i(w) = -F_i(w)$)

$$\hat{w} = \underset{w}{\operatorname{argmin}} \{f(w)\} = \underset{w}{\operatorname{argmin}} \left\{ \frac{1}{n} \sum_{i=1}^n f_i(w) \right\}$$

Tüm olasılıkların toplamının 1 olduğunu,

$$\frac{1}{n} \sum_{i=1}^n \sum_{j=1, j \neq i}^n p_{ij} = 1$$

ve amaç fonksiyona sabit bir sayı eklemenin sonucu değiştirmeyeceği de dikkate alınır, amaç fonksiyon aşağıdaki gibi yazılabilir.

$$\begin{aligned} \hat{w} &= \underset{w}{\operatorname{argmin}} \{1 + f(w)\} \\ &= \underset{w}{\operatorname{argmin}} \left\{ \frac{1}{n} \sum_{i=1}^n \sum_{j=1, j \neq i}^n p_{ij} - \sum_{j=1, j \neq i}^n p_{ij} y_{ij} + \lambda \sum_{r=1}^p w_r^2 \right\} \\ &= \underset{w}{\operatorname{argmin}} \left\{ \frac{1}{n} \sum_{i=1}^n \sum_{j=1, j \neq i}^n p_{ij} \cdot I(y_i, y_j) + \lambda \sum_{r=1}^p w_r^2 \right\} \end{aligned}$$

Denklemin çözümü sınıflandırma hatasını en küçükleyen ağırlık vektörünü vermektedir. Bulunan ağırlıklar, sınıflandırma hatası hesabı (L) için kullanılacaktır.

$$L = \frac{\sum_{j=1}^n w_j e_j}{\sum_{j=1}^n w_j}$$

Burada w_j , j . gözleminin ağırlığı iken e_j ise

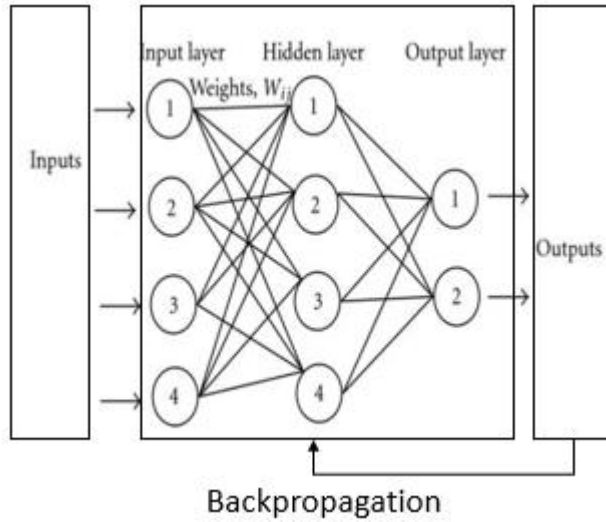
$$e_j = \begin{cases} 1, & \text{eğer sınıflandırma hatalı ise} \\ 0, & \text{eğer sınıflandırma doğru ise} \end{cases}$$

Özetle sınıflandırma hatası, yanlış sınıflandırılan gözlemlerin oranıdır. Belirlenecek bir eşik değere göre özniteliklerin azaltılmasında bu ağırlıklar kullanılmaktadır.

3.5.6.Yapay Sinir Ağı

Çok katmanlı bir yapay sinir ağı denetimli (supervised) ve denetimsiz (unsupervised) olmak üzere iki farklı yaklaşımla eğitilebilir. Denetimli yöntemde her bir girdi setine karşılık olması gereken çıktı, yapay sinir ağından gelen çıktı ile karşılaştırıp, oluşan farka göre ağ bağlantıları güncellenir. Denetimsiz yöntemde ise girdiler arasında kategori oluşturma ve ayırım oluşturma yapay sinir ağına bırakılır. Bu çalışmada denetimli yöntem kullanılmış olup, burada sunulan sonuçlar aşağıda verilen YSA yapısı üzerinden elde edilmiştir.

Klasik sistem yaklaşımı ile baktığımızda yapay sinir ağlarını geri beslemeli açık sistemlere benzetebiliriz.



Şekil 3.7 Örnek bir 3 katmanlı ileri beslemeli yapay sinir ağı

Yapay sinir ağının çıktısı, girdilere, içindeki nöronların ağırlıklarına ve eşik değerlerine bağlıdır. Bir yapay sinir ağının eğitilmesi, aslında çıktı hatasını en küçükleyecek ağ bağlantı ağırlıklarının değerlerinin elde edilmesi işlemi olarak görülebilir.


Çıktı hatası maliyet ya da kayıp fonksiyonu olarak isimlendirilir. e kayıp fonksiyonu çok farklı şekillerde alınabilir. $h(x)$, yapay sinir ağının çıktı fonksiyonu olmak üzere genellikle regresyon için hataların kareleri ortalaması kullanılır:

$$e(w) = e(h(x_n), y_n) = \frac{1}{N} \sum_{i=1}^N (y_i - h(x)_i)^2$$

Sınıflandırma için ise “Cross Entropy” hata fonksiyonu kullanılır. Birden fazla çıktılı bir sınıflandırma aşağıdaki gibi yazılabilir:


$$e(h(x_n), y_n) = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C (y_{ij} \log(h(x)_{ij}) + (1 - y_{ij}) \log(1 - h(x)_{ij})) \quad (3.20)$$

Yapay sinir ağında matematiksel olarak tanımlanan bir nöron insan beyin hücresinin mantıksal bir kopyasıdır. İşlevini yaklaşık olarak temsil etmektedir. İki nöron birbirine bağlandığında bu yeni yapı sinir ağı olarak adlandırılır. Bir nöronun üç tane ana yapısı vardır: (1) “Dentric Tree” girdilerin bulunduğu bölgedir. (2) “Axon” içi elektriğe duyarlı özel bir maddenin bulunduğu uzunca bir yapıdır. Her bir axon’un kendisine has bir eşik değeri bulunur. (3) “Dendrit”ler nöron içerisindeki eşik değerler aşıldığında ateşleme yapan çıktı kanallarıdır (Şekil 3.8).



Şekil 3.8 Bir Nöronun Yapısı (Kaynak : <https://commons.wikimedia.org/wiki/File:Neuron.svg>)

Matematiksel olarak gösterebilmek için iki nöronun birbiri ile olan bağımlı Şekil 3.9’daki gibi özetleyebiliriz.



Şekil 3.9 İki Nöron Arasındaki Bağlantı


x bir nöronun çıktısı, w_{ij} i ve j nöronları arasındaki bağlantının ağırlığı ve b nöron çıktısındaki kayma (bias) olmak üzere i . nöronun çıktısı,

$$x_i = \sum_{j \in \Gamma^{-1}} (w_{ij}x_j + b_i) \quad (3.21)$$

olur. Burada Γ bir haritalama fonksiyonu olup ilgili nöronun bulunduğu katmandaki tüm nöronları içerir. Γ^{-1} ise bir önceki katmandaki tüm nöronları içerir (Svozil, Kvasnieka, Pospichal, 1997).


Nöronun içindeki enerji, onun çıktı vermesi anlamında ateşleme yapmasını ya da yapmamasını sağlar. Bu tamamen eşik değere bağlıdır. Çok çeşitli eşik fonksiyonları bulunmaktadır. Ortak özellikleri; y ekseninde $[-1 \ 1]$ ya da $[0 \ 1]$ aralıklarında ve x ekseninde $[-\infty \ \infty]$ aralığında değişmekte olan ‘türevi alınabilir’ fonksiyon olmalarıdır. Örneğin “Rectified Linear Unit” (ReLU) gibi y ekseninde sınırlanmamış ve “0” noktasında türevi olmayan ama çok tercih edilen fonksiyonlar da vardır. En çok kullanılanlardan bazı örnekler Şekil 3.10’da verilmiştir.

$$\theta(s) = \frac{1}{1+e^{-as}}$$




(Sigmoid Fonksiyonu)

$$\theta(s) = \tanh s$$




(tanh Fonksiyonu)

$$\theta(s) = \begin{cases} 0; & s \leq T \\ 1; & s > T \end{cases}$$



(Linear Fonksiyonu)

$$\theta(s) = \begin{cases} 0; & s \leq 0 \\ s; & s > 0 \end{cases}$$



(ReLU Fonksiyonu)

Şekil 3.10 En çok kullanılan Eşik Fonksiyonları

Yapay sinir ağı hesaplarında geri yayılım, toplam sınıflandırma hatasının azaltılması amacı ile w_{ij} ağırlıklarının ve b bias değerinin değiştirilmesi işlemidir. Bu amaçla geliştirilen algoritmalarından biri olan “Gradient Descent” (GD) algoritması,

$$w(t + 1) = w(t) - \eta \nabla E_{in}(w(t))$$

işleminin bir döngü içerisinde $w(t)$ doğru değere yakınsayana kadar devam ettirilmesidir. Burada t döngü sayısı, w ağırlıklar, η öğrenme oranı, ∇E_{in} o döngüdeki hesaplanan ortalama kayıptır. Döngünün sonlandırılması için belli bir süre çalıştırılması; kayıp seviyesinin belirli bir eşik değerin altına düşmesi ya da sıfıra eşitlenmesi ve ağırlık değerinde uzun bir süre değişim olmaması gibi çeşitli yöntemleri vardır. Ancak hesaplamalar tüm döngülerde tüm nöronlar için yapılmalıdır. Stochastic Gradient Descent (SGD) algoritması, orijinal GD algoritmasının son derece basitleştirilmiş bir halidir (Bottou, 2010). Bütün değerlerin her döngüde tüm nöronlar için hesaplanması yerine, her döngüde rastgele seçilmiş bir nöron için hesaplama yapılmaktadır. Kısaca tanımlanacak olursa, sinir ağının l . katmanında i ve j nöronları arasındaki $w_{ij}^{(l)}$ ağırlıkları aşağıdaki gibi ifade edilebilir:


$$w_{ij}^{(l)} \begin{cases} \text{katman} & 1 \leq l \leq L \\ \text{girdi nöronu} & 0 \leq i \leq d^{(l-1)} \\ \text{çıkıktı nöronu} & 1 \leq j \leq d^{(l)} \end{cases}$$

$(h(x_n), y_n)$ verisi için hesaplanan hata fonksiyonu,

$$e(w) = e(h(x_n), y_n)$$

SGD’yi uygulamak için gradyanın bilinmesine ihtiyaç vardır. Gradyan aşağıdaki formül ile hesaplanabilir.

$$\nabla e(w) = \frac{\partial e(w)}{\partial w_{ij}^{(l)}}$$



Şekil 3.11 İki Nöron arasındaki ilişki

Kısmi türevlerle zincir kuralını uygulayarak çözüme gidilebilir, ancak bu aşamada Şekil 3.10'da verilen eşik fonksiyonlarından biri kullanılarak Şekil 3.11de görüldüğü gibi s_j doğrusal girdisinden $x_i = \theta(s_j)$ fonksiyonel çıktısı elde edilmelidir.

$$\frac{\partial e(w)}{\partial w_{ij}^{(l)}} = \frac{\partial e(w)}{\partial s_j^{(l)}} \cdot \frac{\partial s_j^{(l)}}{\partial w_{ij}^{(l)}}$$

$$\frac{\partial e(w)}{\partial w_{ij}^{(l)}} = \frac{\partial e(w)}{\partial s_j^{(l)}} \cdot x_i^{(l-1)}$$

Çıktı katmanında $l = L$ ve $j = 1$ değerini alır. Hata miktarı δ bu katman için aşağıdaki gibi formüle edilebilir (örnekte aktivasyon fonksiyonu olarak tanjant hiperbolik fonksiyonu alınmıştır) ;

$$\delta_1^{(L)} = \frac{\partial e(w)}{\partial s_1^{(L)}} = \frac{\partial e(h(x_n), y_n)}{\partial s_1^{(L)}} = \frac{\partial (x_1^{(L)} - y_n)}{\partial s_1^{(L)}} = \theta'(s_1^{(L)}) \quad (3.22)$$

Çıktı katmanı değerleri aktivasyon fonksiyonuna giren toplam değerlere göre belirlenmektedir,

$$x_1^{(L)} = \theta(s_1^{(L)}) = \tanh(s_1^{(L)})$$

$$\theta'(s_1^{(L)}) = 1 - \theta^2(s_1^{(L)})$$

$$\delta_j^{(l-1)} = \sum_{i=1}^{d^{(l)}} \frac{\partial e(w)}{\partial s_j^{(l)}} \cdot \frac{\partial s_i^{(l)}}{\partial x_i^{(l-1)}} \cdot \frac{\partial x_i^{(l-1)}}{\partial s_i^{(l-1)}} \quad (3.23)$$

$$\delta_j^{(l-1)} = \sum_{i=1}^{d^{(l)}} \delta_j^{(l)} \cdot w_{ij}^{(l)} \cdot \theta'(s_i^{(l-1)})$$

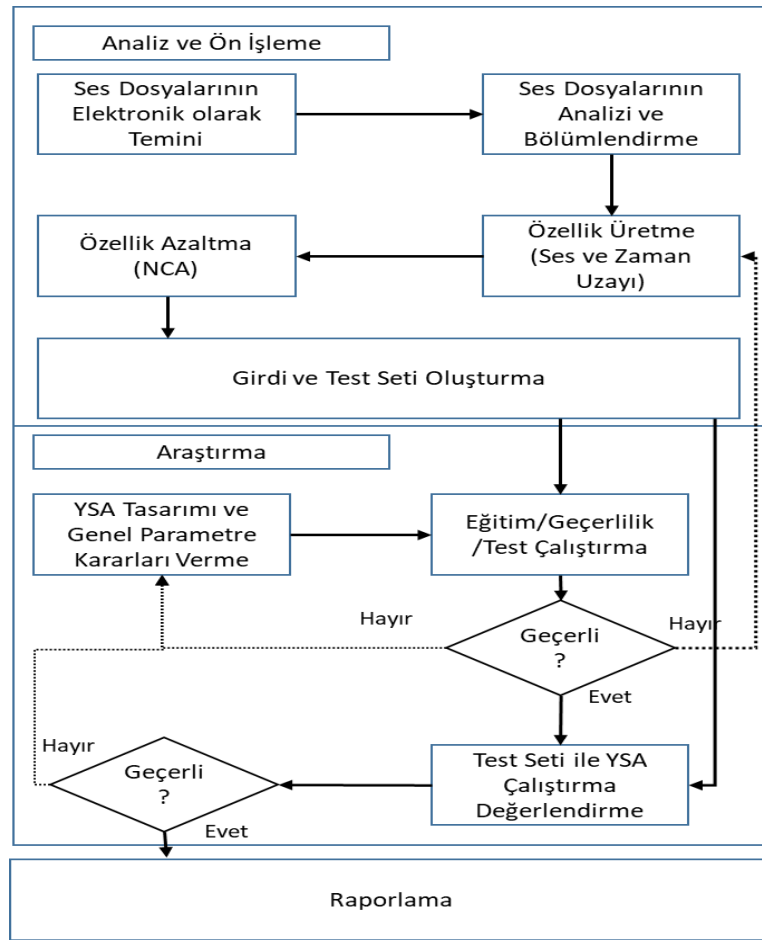
$$\delta_j^{(l-1)} = (1 - x_i^{(l-1)})^2 \cdot \sum_{i=1}^{d^{(l)}} \delta_j^{(l)} \cdot w_{ij}^{(l)}$$

Geri yayılım yapay sinir ağı hesap işlemleri yükünün en önemli kısmını oluşturmaktadır. Geri yayılım algoritması aşağıdaki gibi verilebilir (Abu-Mostafa, 2012):

1. l katmanında i ve j düğümleri arasındaki ağırlıklara ($w_{ij}^{(l)}$) rastgele olarak ilk değer ata
2. $l = 0,1,2,3, \dots$ katmanları için aşağıdakileri yap
 - a. $n \in \{1,2,3, \dots, N\}$ verisi için aşağıdakileri yap
 - i. İleri yönlü: Bütün $x_i^{(l)}$ değerlerini hesapla; Denklem (3.21)
 - ii. Geri yönlü: Bütün $\delta_j^{(l)}$ değerlerini hesapla; Denklem (3.22 - 3.23)
 - iii. Ağırlıkları güncelle : $w_{ij}^{(l)} = w_{ij}^{(l)} - \eta X_i^{(l-1)} \delta_j^{(l)}$
 - iv. Durma kriterine ulaşana kadar döngüye devam et. Durma karar kriteri ile ilgili farklı yaklaşımlar bulunmaktadır: Döngü sayısını sınırlamak, eğitim kazanç miktarını sınırlamak gibi.
3. Sonuç ağırlıkları döndür ($w_{ij}^{(l)}$).

3.6.Yöntem

Bu çalışmada, önceki bölümlerde örüntü sınıflandırma konularında başarılı olmuş ve öznelik seçme anlamında konuya uygun olan yöntemler belirlenmiştir. Şekil 3.12’de işlem akış yapısı verilen yaklaşımla ses kayıt ve veri seti hazırlama sonrası ses kayıtlarının ön işleme tabi tutulması ve ardından kaynaklarda belirtilen yöntemlerle öznelik üretme hesaplamaları yapılacağı tanımlanmıştır. Üretilen çok sayıdaki öznelik istatistiksel bir yöntem ile azaltılarak sadeleştirilmiştir. Böylece oluşturulmuş olan Yapay Sinir Ağı (YSA)’nın girdileri hazırlanmıştır. YSA oluşturulduktan sonra veri seti ve seçilen öznelikler ile eğitim , test ve geçerleme yapılmış, performans ölçütleri kayıt edilmiştir. YSA eğitiminde kullanılmayan belli bir grup ses verisi ile gerçek verilerle test çalıştırması sonrası, etkinlik ölçüm ve değerlendirmesi yapılmıştır.



Şekil 3.12. Ses Kalite Problemlerinin Çözümünde Kullanılan Yöntem.

3.6.1.Ses Kayıt ve Veri Seti Hazırlama

Seri akan bir montaj hattında üretilen ayna katlama mekanizmaları belirli bir üretim hızında konveyörden çıktıktan sonra “Class 1000“ sessiz oda kalitesindeki kapalı bir ortamda çalışanların elektrostatik önlemleri alınmış ve özel kıyafetlerle çalıştığı koşullarda gürültü testine girmektedir.

Veri toplama tam otomatik montaj hattının sonuna kurulmuş olan Son Kontrol bankosu aracılığı ile yapılmaktadır. Bitmiş ürünler son kontrol bankosuna paletler üzerinde gelir. Ses yalıtkanlığını sağlamak için üst üste iki ses geçirmez duvarla kaplı kutunun içindeki mekanizmaya gelen palet sensörleri harekete geçirir ve palet durdurulur. Otomatik olarak bitmiş ürüne elektrik soketinden elektrik verilir ve motor açma kapama hareketi boşa olarak yaptırılır. Motorun çektiği akım değerleri ve çalışma süresince çıkardığı ses kayıt edilir. İki adet mikrofon tarafından kayıt edilen ses, National Instruments NI4431 USB1 tip veri toplayıcısına erişir. RACK ses analizi veri toplama yazılımı ses kaydını (44.100adet/sn örnekleme hızında) .uff dosyası formatında sunucuya gönderir ve dosyalar gün-saat-dakika-saniye-sıra no formatında kayıt edilir. Burada ses verisi .uff formatında şirket veri tabanına kayıt edilir. Kayıt sırasında dosya adı tarih-saat-dakika-saniye-sıra numarası olarak kayıt yapılmakta ve izlenebilirlik temin edilmektedir.

Ardından .uff uzantılı dosyalar National Instruments’in sağladığı dönüşüm programı aracılığı ile yazılım programımızın kullanabileceği .wav uzantılı dosyalara tek tek dönüştürülür. Ses dosyalarının uzunluğu toplamda 3,55 saniye olup 44.100 Hz örnekleme hızında toplamda 156.555 veri içermektedir.

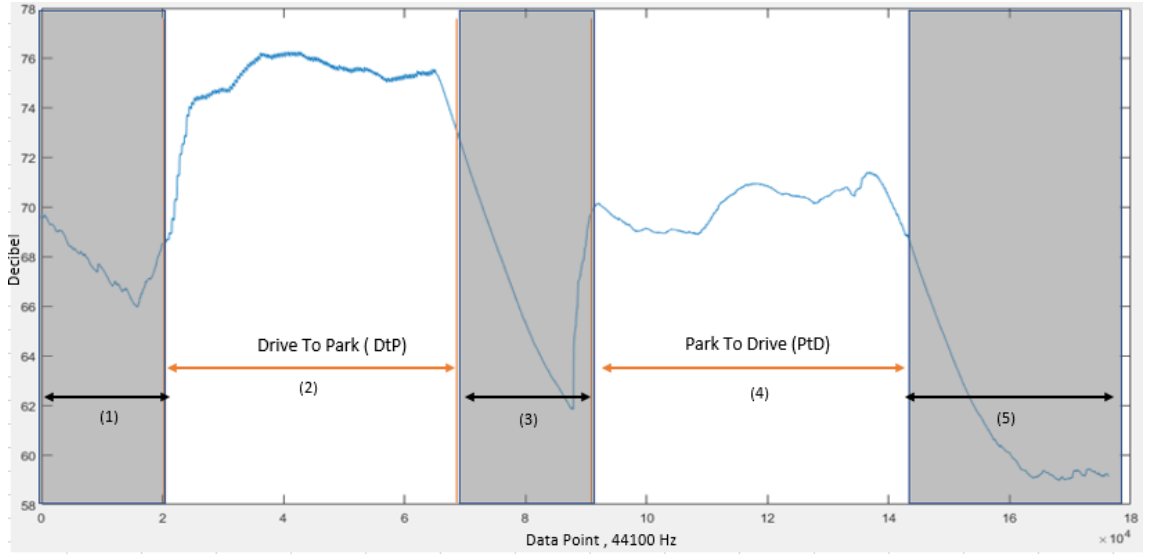
Eğitim, test ve validasyon için hazırlığı yapılmış veri setine ihtiyaç olduğu için Üretim Kalite Bölümünden bir çalışma yapılması istenmiş ve ses dosyaları hata tipleri etiketli bir şekilde temin edilmiştir. Çalışma 20 adet ses dosyası ile başlamış, ancak veriler zaman içerisinde 161 adetlik set ve 50 adet rastgele seçilen test seti ile bitirilmiştir. Öznel bir çalışma olduğu için Üretim Kalite Bölümünden konunun uzmanı bir kişi tarafından üretimden gelen veriler tek tek dinlenerek, kontrol edilmiş ve gerekirse düzeltmeler yapılarak dosya son haline getirilmiştir.

Çizelge 3.4. Eşleştirme Tablosundan bir Kesit

PF4.1 HATALI PARÇA BİLGİSİ (QW NOK)							
No	Referans	Hata Nedeni	İzlenebilirlik-1		Hata Yeri		Eşleşme (.wav)
			Gün	Saat	DtP	PtD	File Name
1	21992363	Click Clik	14.09.2018	22:08:37	X		Sample1
2	21992363	Yüksek Ses	11.10.2018	16:59:05		X	Sample4
3	21992364	Yüksek Ses	11.10.2018	23:35:09		X	Sample7
4	21982475	Osilasyon	6.10.2018	01:19:53	X		Sample8
...

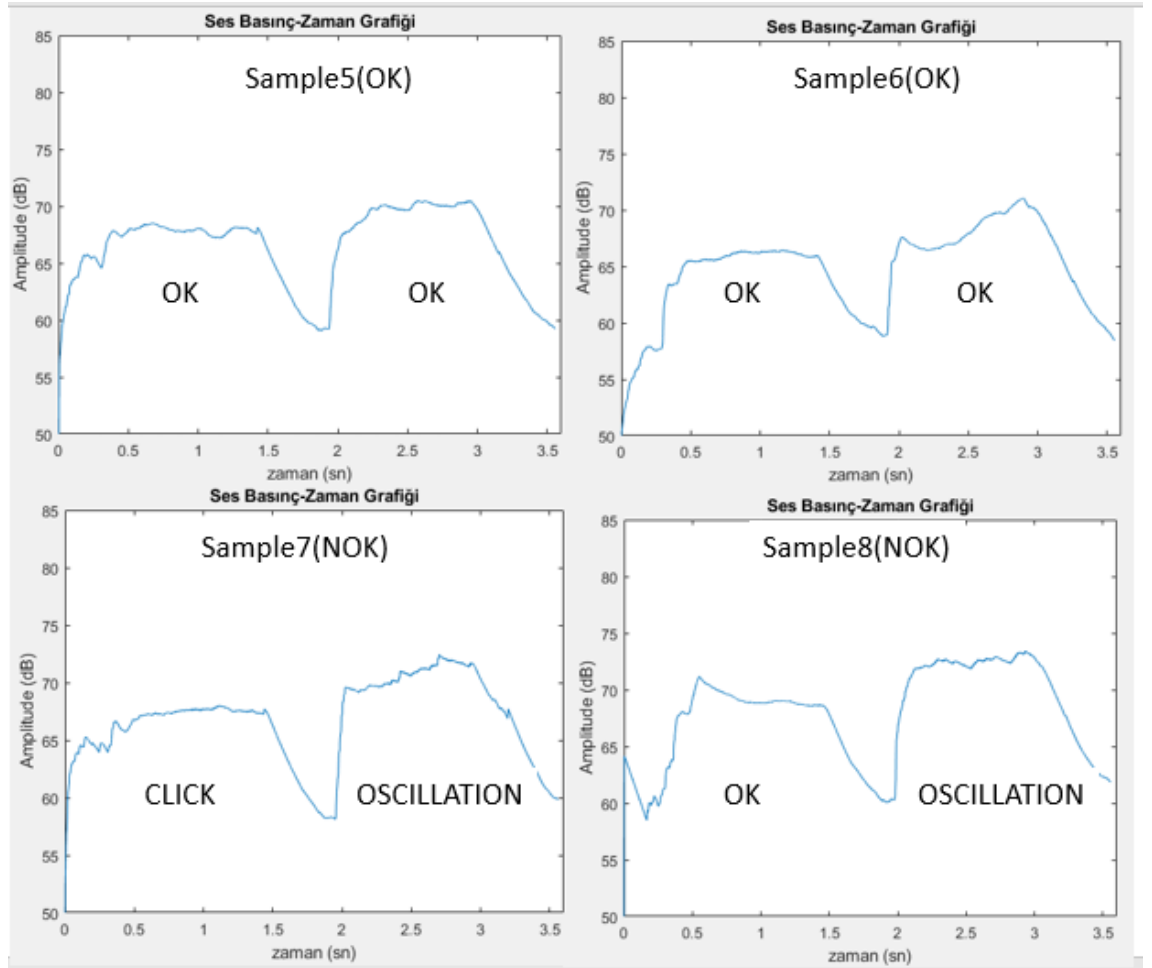
3.6.2. Ses Ön İşleme

Her bir ses dosyasının süresi 3.55 sn olup, 44.100 Hz örnekleme oranı ile 156.555 örnek içermektedir. Bazı ses dosyaları 4 sn olup 176.400 veri noktası içermektedir. Analiz göstermektedir ki, bu ekstra uzunluk test bankosunun mekanik gecikmesinden kaynaklanmakta ve sesin sabit ayrışım noktalarına etki etmemektedir. Bu ayrım noktaları açma başlama, açma bitiş, kapama başlama, kapama bitiş olarak söylenebilir. Ortam gürültüsünün bozucu etkisinden kaçınmak için ses iki ana gruba ayrılmıştır; açma ve kapama (her biri 1.26 sn).



Şekil 3.13. Ayna açma kapama mekanizmasının Ses Basınç Seviyesi-SPL Değişimi

Şekil 3.13'te gri ile işaretlenen kısımlar pasif ve parça ses kalitesi ile ilgisiz olan zaman aralıklarıdır. Test aşamasında mekanizmadan gelen ses beş aşamaya bölünebilir ve aşamaları soldan sağa şöylece sıralanabilir: (1) Test başlangıcında bir süre bekleme, (2) Ayna katlama mekanizmasının kapanması, (3) Kapanma ve açılma arasında bekleme, (4) Ayna katlama mekanizmasının açılması, (5) Test sonunda bir süre bekleme. Bu aşamalardan (1), (3) ve (5)'in ürün kalitesi ile ilgili olmadığı açıktır. (2) ve (4) bölümleri arasında boşluk olduğu için ses dosyasının bölünmesi ve her bölünen kısım için ayrı ayrı öznelitek üretme, azaltma, yapay sinir ağı eğitme ve kalite seviyesini belirleme işlemleri yapılmalıdır. Ancak iki bölümden herhangi birinde gözlenebilecek kalite hatasında o ses dosyasının elde edildiği ürün hatalı kabul edilmiştir. Diğer taraftan SPL grafiği hatanın varlığı ya da yokluğu ile ilgili bir bilgi içermemektedir. Şekil 3.14'te farklı durumlardaki ses dosyalarının SPL grafikleri sunulmuştur.



Şekil 3.14. Farklı ürün örneklerinde normal ve hatalı ürün için SPL değişimi

3.6.3. Öznitelik Üretme

Yapılan veri toplama çalışması sonrası, frekans aralığı 0 – 22.050 Hz arasında değişen 1,26 sn uzunluğunda 55.566 veri noktasından oluşan örnekler elde edilmiştir. Özniteliklerin, zaman uzayı ve frekans uzayından elde edilenler olarak iki ana gruba ayrılabilceği daha önce belirtilmişti. Geliştirilen bir program ile bir döngü içerisinde ses dosyası okunduktan sonra, önceki bölümde belirtilen yöntemle zaman uzayında örneklenmiş DtP ve PtD olarak iki ses kaydı oluşturulmaktadır. Daha sonra öznitelik üretme sürecinde bu iki kayıt için ayrı ayrı maksimum ses seviyelerinin Denklem (3.1) ve ortalamalarının Denklem (3.2) ile farkları hesaplanmaktadır.

Bölüm 3.5.2’de açıklandığı gibi Hanning penceresi uygulanarak ses verisi zaman uzayından frekans uzayına taşınmıştır. Denklem (3.15) esas alınarak geliştirilen ilgili Matlab kodu aşağıda verilmiştir.

```
WpTD = PtD.*hanning(length(PtD))';  
WDtP = DtP.*hanning(length(DtP))';  
WpTDF= fft(WpTD,Fs);  
WDtPF= fft(WDtP,Fs);
```

Şekil 3.15. FFT dönüşümü yapan Matlab kodu

Daha sonra Denklem (3.16) ile ilk 3 tepe değeri için otokorelasyon hesaplanmıştır.

Bölüm 3.5.1’de zaman uzayında geçerli sınıflandırma potansiyeli bulunan ölçütlerden standart sapma (3.3), tepe değeri (3.4), eğrilik (3.5), kurtosis (3.6), ortalama köklerin karesi (3.7), ortalama karelerin kökü (3.8), crest faktörü (3.9), clearance faktörü (3.10), şekil faktörü (3.11), etki faktörü (3.12) denklemleri kullanılarak sınıflandırıcı Yapay Sinir Ağı için girdi olmak üzere veriler üzerinden hesaplanmıştır. Yine seçilmiş girdi olarak minimum power (3.13) ve anlamlı derecede yüksek ses basınç değerlerinin sayısı (3.14) denklemleri ile hesaplanmıştır.

Fourier Dönüşümü sonrası elde edilen 22.050 adet 1 Hz bant genişliğindeki her bir genlik değerinin yapay sinir ağına bir girdi olarak alınması hesaplama süresini çok uzatacağı ve çalışmayı pratikte uygulanabilir olma hedefinden saptıracağı için insan kulağının hassasiyet seviyesinin üzerindeki 10.000Hz ve üzeri frekanslar hesaplamadan çıkarılmıştır. Buna göre DtP ve PtD şeklinde ikiye ayrılmış olan ses bölümlerinin FFT ile elde edilen frekanslardaki genlikler (mutlak değer) alınmıştır.

Üzerinde çalışılan farklı yaklaşımlardan çıkan sonuç; bu problem için frekans bantlarını genişletmenin bilgiyi önemli oranda kayba uğrattığı ve tekil frekans büyüklüklerinin daha önemli olduğudur.

DtP ve PtD ses dosyalarının her biri için Çizelge 3.5'te verilen öznelilikler hesaplanmıştır.

Çizelge 3.5. Çalışmada dikkate alınan özneliliklerin tam listesi

SIRA	ÖZELLİK ADI	ÖZELLİK AÇIKLAMASI
1-10000	FREQUENCY VALUE 1 to 10000	1 ila 10000 Hz arasındaki her frekansın değeri
10001	MAXdB	En yüksek Desibel değeri
10002	AVGdB	Anlık Desibel değerlerinin Ortalaması
10003	DELTA dBMAX	En yüksek Desibel değerlerinin farkı
10004	DELTA dBAVG	Ortalama Desibel değerlerinin farkı
10005	AUTOCORR PEAK @0	Otokorelasyon orta değeri
10006	AUTOCORR PEAK @1	Otokorelasyon 1.zirve değeri
10007	AUTOCORR PEAK @2	Otokorelasyon 2.zirve değeri
10008	AVGOFMAXINSTANTENTROPY	En yüksek anlık entropi değerleri ortalaması
10009	POSITIONOFMAXINSTANTENTROPY	En yüksek anlık entropi değerinin yeri
10010	POSITIONOFMAXHILBERTSPECTRUM	En yüksek Hilbert spektrum değerinin yeri
10011	MINIMUM POWER	En düşük ses basınç değeri
10012	NUMBER OF PEAKS	Anlamli yüksek ses basınç değerlerinin sayısı
10013	STD DEV	Standart Sapma
10014	PEAK	Tepe değeri
10015	SKEWNESS	Eğrilik değeri
10016	KURTOSIS	Kurtosis değeri
10017	CREST FACTOR	Crest Faktör değeri
10018	CLEARANCE FACTOR	Clearance Faktör değeri
10019	SHAPE FACTOR	Shape Faktör değeri
10020	IMPACT FACTOR	Impact Faktör değeri
10021	SMR	Ortalama köklerin karesi
10022	RMS	Ortalama karelerin kökü

3.6.4. Öznitelik Seçimi ve Azaltma

Veri seti içerisinde çok küçük ve çok büyük rakamlar bulunduğu için öncelikle her veri kendi içinde normalize edilmiştir.

Özniteliklerin seçimi için Bölüm 3.5.5 de verilen NCA yöntemi kullanılmıştır. Bu yöntemde bir düzenleme parametresi (λ) bulunmaktadır. Bu parametrenin ince ayarı için Matlab dökümantasyonunda bulunan aşağıdaki adımlar izlenmiştir:

1. Anlamlı öznitelikleri belirlemek için herhangi bir ‘fitting’ yapmadan genelleştirme hataları hesaplanır.
2. Regülerizasyon parametresi olmadan ($\lambda = 0$) Şekil 3.4’te verilen yöntemle (NCFS) tüm öznitelikler için önem dereceleri hesaplanır.
3. İki fitting arasındaki kayıp değerler karşılaştırılır. λ değerini ince ayar yapmanın sonucu iyileştirip iyileştirmeyeceği değerlendirilir.
4. Veri seti 5 katlı çapraz validasyon için bölünür.
5. Her bir kattaki veri setini kullanarak daha önceden oluşturulan λ değerleri için Şekil 3.4’te verilen yöntemle tüm öznitelikler için önem dereceleri hesaplanır (λ değerleri 0’ dan başlamak üzere veri setinin uzunluğunu dikkate alarak incelenmek istenen değer sayısı kadar oluşturulur. 0,02 – 0,04 – 0,06 ...gibi).
6. İlgili set için sınıflandırma hatası (Loss) kayıp fonksiyonu hesaplanır.
7. Bu hesaplama tüm kat ve λ değerleri için yapılır.
8. Her bir λ değeri için her katta elde edilen kayıp fonksiyon değerlerin ortalaması alınır.
9. En düşük hatayı (kayıp fonksiyonunu) veren λ değeri bulunur ve Öznitelik grafiği çizilir. Seçilen Öznitelikler hafızada tutulur ve kayıt edilir.

procedure $NCFS(T, \alpha, \sigma, \lambda, \eta) \triangleright T$: eğitim seti, α başlangıç adım uzunluğu, σ : kernel eni, λ : düzenleme parametresi, η : küçük pozitif sabit;

Initialization : $w^{(0)} = (1, 1, \dots, 1)$, $\varepsilon^{(0)} = -\infty$, $t = 0$

Repeat

for $i=1, \dots, N$ **do**

 compute p_{ij} and p_i using $w^{(t)}$

for $l = 1, \dots, d$ **do**

$\Delta_l = 2\left(\frac{1}{\sigma} \sum_i (p_i \sum_{j \neq i} p_{ij} |x_{il} - x_{jl}| - \sum_j y_{ij} p_{ij} |x_{il} - x_{jl}|) - \lambda\right) w_l^{(t)}$

$t=t+1$

$w^{(t)} = w^{(t-1)} + \alpha \Delta$

$\varepsilon^{(t)} = \xi(w^{(t-1)})$

if $\varepsilon^{(t)} > \varepsilon^{(t-1)}$ **then**

$\alpha = 1.01\alpha$

else

$\alpha = 0.4\alpha$

until $|e^{(t)} - e^{(t-1)}| < \eta$

$w = w^{(t)}$

return w


Şekil 3.16. NCFS Komşuluk Bileşke Analizi algoritması (Yang, Wang, Zuo, 2012)

3.6.5. Yapay Sinir Ağı Oluşturma, Eğitim ve Validasyon ve Performans Ölçümü

Denetimli Yapay Sinir Ağı oluşturulmasının ilk aşaması, EK 1’de verilmiş olan eğitim/test/validasyon verisine ön işleme uygulanarak seçilmiş özniteliklerin girdi olarak hazırlanması ve veri etiketlerinin de “beklenen çıktı” dosyasına kayıt edilmesidir. YSA parametrelerinin belirlenmesi sıradaki en önemli iştir. Hyper-parametrization olarak da adlandırılan bu aşama aslında sonsuz olasılık içermektedir. Örneğin Öğrenme oranı $\alpha = 0.1 - 0.001$ aralığında değerler alabilir. Ancak bu çalışmada Bölüm 3.4.3’te belirtildiği gibi SGD algoritmalarında başarılı olduğu uygulayıcılarca da belirtilen $\alpha = 0.01$ değeri kullanılmıştır.

Bir tane gizli katman olması doğrusal olmayan fonksiyonların oluşturulması için yeterli olduğu halde yapılan çeşitli denemelerde üç gizli katmanlı yapıda en iyi sonuç alındığı için gizli katman sayısı deneme yanılma yaklaşımı ile üç gizli katman olarak belirlenmiştir.

YSA'a girdi olarak Çizelge 3.5'deki özniteliklerden elenenler sonucu Çizelge 4.1'de verildiği gibi 65 adet öznitelik belirlendi. Çıktı sayısı da hata tipleri dikkate alınarak 6 adet olarak alındı. Yapay sinir ağı çıktı katmanında her bir hata tipi için bir olasılık değeri vermektedir. O nedenle çıktı katmanında ilk bileşen çıktı OK, 2-5 arası çıktılar farklı hata tiplerine karşılık gelirken, altıncı çıktı 'Diğer' olarak belirlenmiştir. Böylece her bir ses parçası için 1-6 arası çıktılar için olasılıklar üretilmiştir. Oluşturulan YSA, Matlab ortamında 65G/18H1/12H2/6H3/6Ç gösterimi ile kodlanabilir.



Şekil 3.17. Matlab ortamında 65G/18H1/12H2/6H3/6Ç ile tanımlanan YSA yapısı

Her gizli katmanda bir Sigmoid eşik fonksiyonu, Çıktı katmanında ise bir SoftMax eşik fonksiyonu bulunmaktadır. Bölüm 3.4.3'te eşik fonksiyonlarına değinilmişti ancak, SoftMax fonksiyonunu açmak gerekirse; her çıktı için bir olasılık değeri döndüğü ve olasılıkların toplamının 1'e eşit olduğu söylenebilir. y_i değerlerinin son katmanın ürettiği çıktı değerleri olduğu varsayılırsa, elde edilebilecek SoftMax ifadesi

$$S(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}}$$

olarak verilebilir. Böylece her ses parçası için altı adet olasılık değeri sistem tarafından üretilecektir.

161 adetlik veri rastgele olarak (Data Division : Random)) bölünmüştür. 113 adet (%70) örnek eğitim, 24 adet (%15) validasyon ve 24 adet (%15) test için ayrılmıştır.


Eğitim yöntemi (Training : Scaled Conjugate Gradient)) Ölçeklendirilmiş Eşlenik Eğim olup, öğrenme oranı 0.01'dir. Performans ölçme yöntemi olarak CrossEntropy

seçilmiştir (Performance: Cross-Entropy). Hedef Çıktılar, Sistem Çıktıları, Optimal Ağırlıkları baz alarak yapılan hesaplamada doğruya yakın tahmin yapıldığında hafifçe cezalandırılan fonksiyon, doğrudan uzak tahminlerin sayısı ve büyüklüğü arttıkça çok büyük ceza puanları üretmektedir. Amaç, performans değerini mümkün olduğunca '0' a yakın tutmaktır. CrossEntropy Çıktı(y) – Hedef(t) çiftlerinin her biri için Matlab komutu olarak

$$\text{CrossEntropy} = - t.*\log(y)$$

formülü ile hesaplanırken, toplam performans yukarıdaki CrossEntropy tekil değerlerinin aritmetik ortalamasıdır. Program çalıştırıldıktan sonra DtP grubu için Performans değeri 0,0202, PtD grubu için Cross Entropy değeri 0,00533 olarak bulunmuştur. Görüldüğü üzere PtD grubunda çok daha iyi bir eğitim performansı vardır.

Diğer taraftan eğitim performansının iyi olması tek başına hiçbir şey ifade etmez. Çünkü öğrenme sürecinde yapılabilecek en büyük risk veri seti için YSA'nın defalarca eğitim/test/validasyon sürecine sokulup %100'e yakın başarı oranlarına ulaşıldığında hiç görülmemiş yeni örneklerle uygulama yapıldığında son derece kötü sonuçlar elde edilmesidir. "Overfitting" terimi ile verilen bu durum yapay sinir ağının sadece örneklem havuzunu çok iyi öğrendiğini ancak örneklerin geldiği genel durum uzayının gerçeklerinden de uzaklaştığını ifade eder. (Şekil 3.19)



Şekil 3.18. Optimum Eğitim Seviyesi

3.6.6. Yeni Ses Dosyaları ile YSA Testi

YSA bağlantı ağırlıkları sadece eğitim veri setinden elde edilmiş iken elde edilen yüksek sınıflandırma başarısı için YSA'nın eğitim verisine aşırı uyum sağlamış olduğu ancak genelleme anlamında bu başarının geçerli olmadığı varsayılmıştır. Bu varsayımı test etmek amacıyla daha önce değerlendirilmemiş yeni ses verileri dikkate alınmıştır. Öncelikle Kalite Departmanınca özellikle hatalı ve hataları farklı çok sayıda ürün için izlenebilirlik verisi kullanılarak ilgili ses dosyalarına erişim sağlanıp, söz konusu veriler ön işlem aşamalarından geçirilmiştir. Toplamda 50 adet ses dosyasının 21 adedi kalite departmanı tarafından iletilmiş seslerden; kalanları da rastgele seçilmiş ses dosyalarından oluşturulmuştur. Programa bir eklenti yapılarak yeni test dosyaları için girdi değerleri hesaplandıktan sonra önceden eğitilmiş olan YSA ile bu seslerin de sınıflandırması yapılmıştır.

3.6.7. Etkinlik Ölçüm ve Değerlendirme

Bir ayna katlama mekanizmasının sesinin "OK" olarak değerlendirilmesi için aşağıdaki şartlar sağlanmalıdır:

- a. Sesin her iki kısmı birden (DtP, PtD) OK olarak etiketlenmelidir.
- b. Tip1 ve Tip2 hata tiplerinin birbirinden farklı maliyetleri vardır. Önceki bölümlerde açıklandığı üzere NOK parçanın OK olarak sınıflandırılması ve hatalı ürünün müşteriye ulaşması çok büyük maliyetler anlamına geldiğinden olabildiğince kaçınılmalıdır. Bundan kaçınırken Tip2 hata aşırı artarsa, bu durumda da işletme maliyetleri artar ve karlılık düşer. Verilenleri dikkate alarak "hatalar lehine" eşikler düzenlenmiştir. Detaylandırılacak olursa ;
 - i. YSA'nda 1 No'lu çıktı 'OK' anlamına gelmektedir. Diğerleri ise 'NOK' anlamına gelmektedir. OK olasılığı 0,5'in altında olduğu durumlarda en yüksek değer bile olsa değerlendirmede 'NOK' olacak ve ikinci en yüksek olasılık seçilecektir. Örneğin aşağıdaki gibi bir olasılık sonucu çıkarsa değerlendirme HATA 2 olarak alınacaktır.

OK	HATA1	HATA2	HATA3	HATA4 ...
0,45	0,02	0,32	0,01	0,21

Yapay sinir ağı çıktılarının elde edildiği programda, yukarıdaki akışı sağlayacak şekilde DtP ve PtD sonuçlarını ayrı ayrı yorumlayıp, birleştirecek bir alt program yazılmış ve değerlendirmeler yapılmıştır.

Sonuçların değerlendirilmesi için sadece OK / NOK seçiminin doğruluğu esas alınmıştır. Seçilen hata tipinin doğru seçilip seçilmediği ile ilgilenilmemiştir. Bunun iki nedeni vardır. Birincisi pratikte hatalı ayna katlama mekanizması bir kere sistem tarafından ayrıldıktan sonra kalite değerlendirme ve yeniden işlem prosesine gitmektedir. Hata tipi kontrolünün tekrar yapılmasının yanında ilgili parçaya yapılan işlemler hiçbir şekilde değişmemektedir. Hata tipi sınıflandırmasının bu nedenle herhangi bir katma değer yaratmadığı ve sonuca etkisi olmadığı değerlendirilmiştir. İkinci neden ise eldeki hatalı ürün sayısının her bir hata tipi için genelleştirme yapmaya yetecek miktarda olmamasıdır. Bazı hata tiplerinden son derece az örnek bulunduğu için hata bazında değerlendirme yapmanın istatistiksel anlamı olmayacaktır. Bir parçada birden fazla hata tipi aynı anda da bulunabilir. Farklı hata tiplerinden en belirgin olanı ile isimlendirmek için çalışmada çıktı olarak beş farklı hata tipi tanımlanmıştır.

Böylece basitleştirilmiş OK/NOK durumu ile test verisi üzerinden Kesinlik, Doğruluk ve Duyarlılık hesaplanmış ve çalışma sonucu olarak raporlanmıştır.

4. BULGULAR

4.1. Yazılım ve Donanım

Uygulamada kullanılan yazılım MATLAB (Uludağ Üniversitesi Akademik Lisansı) olup Wavelet Toolbox, Signal Processing Toolbox, DSP System Toolbox, Audio Toolbox, Deep Learning Toolbox yüklenmiş ve komutları kullanılmıştır.

Kullanılan bilgisayar donanım kritik özellikleri: İşlemcisi Intel i5-5200U CPU @2.20 GHz, Hafıza kapasitesi 16GB RAM ve Hard Disk kapasitesi 120GB SDD, Ekran Kartı NVIDIA GeForce 830M 2GB olup İşletim Sistemi Windows 10'dur.

Çalışma için öncelikle .uff tipi dosyaların .wav tipine dönüştürülmesi gerekmektedir. Kodlamanın yapılacağı MATLAB programı .uff tipi dosyaları doğrudan okuyamadığı için yine National Instruments LabView dönüşüm eklentisi lisanslı bir program kullanıldı. Şirket sunucusundan indirilen ses dosyaları bu aracı program ile birlikte .wav formatına çevrilmiştir.


4.2. Veri Seti

Çalışmada kullanılan toplam ses dosyası sayısı 211 adettir. İlk 161 ve ikinci 50 adet ses dosyasının kalite durumu EK 1'de sunulmuştur. EK 2'de ise bu 161+50 ses dosyasından elde edilen seçilmiş kriterlerin özet değerleri sunulmuştur.

Test, Eğitim ve Geçerleme dosyalarının etiketlenmiş hali EK 1'de tam haliyle sunulmuştur. Böylece yapay sinir ağıımızda kullanacağımız etiketlenmiş çıktı dosyaları hazırlanmıştır.


4.3. Analiz

Bölüm 3.6.4'te açıklandığı üzere Çizelge 3.6'daki girdilere uygulanan NCFS yöntemi ile öznitelik seçme ve azaltmaya gidilmiştir. Bulunan sonuçlar Şekil 4.1 ve Şekil 4.2'de verilmiştir.



DtP
AUTOCORR PEAK @0
AUTOCORR PEAK @1
AUTOCORR PEAK @2
MINIMUM FREQUENCY F
Freq: 2
Freq: 27
Freq: 28
Freq: 421
Freq: 1196
Freq: 2326
Freq: 2357
Freq: 2358
Freq: 2398
Freq: 2415
Freq: 4238
Freq: 4310
Freq: 4446
Freq: 4700
Freq: 5956
Freq: 6046
Freq: 6986
Freq: 7186
Freq: 8332
Freq: 8642
Freq: 8717
Freq: 8921
Freq: 8930
Freq: 8966
Freq: 9034
Freq: 9058
STD DEV
PEAK
SKEWNESS
SHAPE FACTOR

Şekil 4.1. DtP / Seçilen Öznitelik Sayısı 34 /



PtD
Freq: 145
Freq: 872
Freq: 921
Freq: 1624
Freq: 3491
Freq: 3492
Freq: 3761
Freq: 3788
Freq: 3893
Freq: 3895
Freq: 3896
Freq: 3960
Freq: 3961
Freq: 4531
Freq: 4605
Freq: 4638
Freq: 4639
Freq: 4944
Freq: 7429
Freq: 8036
Freq: 8326
Freq: 8328
Freq: 8346
Freq: 8347
Freq: 8440
Freq: 9699
PEAK
KURTOSIS

Şekil 4.2. PtD / Seçilen Öznitelik Sayısı 28 /

Çizelge 3.6’da zaman ve frekans uzaylarından sınıflandırmaya anlamlı katkısı bulunan toplamda 61 adet öznitelik özetlenmiştir. 61 adet seçilen özneliğin yanına müşteri tarafından belirlenmiş ses seviyesi farkı için 4 adet daha öznitelik ekleyince toplamda 65

adet girdiye ulaşılmıştır. İkinci bir program (EK 3: TezStepFinalafterNCA.m /Bölüm 1/) ile sadece seçilen öznelikler hesaplatılmıştır. Hesaplanan değerler EK 2’de verilmiştir.

Diğer taraftan ‘Confusion Matrix’ Karışıklık Matrisi de eğitim, geçerlilik ve test aşamalarının ve toplamda YSA’nın öğrenme etkinliğini göstermektedir. Şekil 4.3 ve Şekil 4.4’te yapılan Karışıklık Matrisleri verilmiştir. Görüleceği üzere DtP %97.5 doğruluk, PtD %99.4 doğruluk seviyesine ulaşmıştır.

Genel doğruluk ise bu iki rakamın çarpımından daha küçük olacaktır. Nitekim iki değer çarpımı %96,9 iken gerçekte test verileri ile yapılan gerçek hayat testinde %96,0 doğruluğa ulaşılmıştır.

KARIŞIKLIK MATRİSİ (DtP)

ÇIKTI	1	146	0	1	0	0	1	148	98.6%
	2	0	2	0	0	0	0	2	0.0%
	3	0	0	0	0	0	0	0	N/A
	4	0	0	0	4	0	0	4	0.0%
	5	0	1	0	0	5	1	7	0.0%
	6	0	0	0	0	0	0	0	N/A
		146	3	1	4	5	2	161	
	100.0%	0.0%	0.0%	100.0%	100.0%	0.0%		97.5%	
	1	2	3	4	5	6			
	HEDEF								

Şekil 4.3. DtP Karışıklık Matrisi (161 örnek)

KARIŞIKLIK MATRİSİ (PtD)

ÇIKTI	1	125	0	0	0	1	0	126	99.2%
	2	0	15	0	0	0	0	15	0.0%
	3	0	0	4	0	0	0	4	0.0%
	4	0	0	0	5	0	0	5	0.0%
	5	0	0	0	0	8	0	8	0.0%
	6	0	0	0	0	0	3	3	0.0%
		125	15	4	5	9	3	161	99.4%
	100.0%	0.0%	100.0%	100.0%	88.9%	100.0%			
	1	2	3	4	5	6			
				HEDEF					

Şekil 4.4. PtD Karışıklık Matrisi (161 Örnek)

Çizelge 4.1. YSA'ya Girdi Olarak Seçilmiş Öznitelikler

					DtP	PtD
	ZAMAN UZAYI	STANDART SAPMA				X
ZİRVE				X	X	
SKEWNESS				X		
KURTOSIS					X	
SHAPE FACTOR				X		
MINIMUM POWER				X		
AUTOCORRELATION ORTA TEPE DEĞERİ				X		
AUTOCORRELATION 1. TEPE DEĞERİ				X		
AUTOCORRELATION 2. TEPE DEĞERİ				X		
FREKANS UZAYI	MAGNITUDE		DtP	PtD	MAGNITUDE	
	2 Hz		X		4531 Hz	
	27 Hz		X		4605 Hz	
	28 Hz		X		4638 Hz	
	145 Hz			X	4639 Hz	
	421 Hz		X		4700 Hz	
	872 Hz			X	4944 Hz	
	921 Hz			X	5956 Hz	
	1196 Hz		X		6046 Hz	
	1624 Hz			X	6986 Hz	
	2326 Hz		X		7186 Hz	
	2357 Hz		X		7429 Hz	
	2358 Hz		X		8036 Hz	
	2398 Hz		X		8326 Hz	
	2415 Hz		X		8328 Hz	
	3491 Hz			X	8332 Hz	
	3492 Hz			X	8346 Hz	
	3761 Hz			X	8347 Hz	
	3788 Hz			X	8440 Hz	
	3893 Hz			X	8642 Hz	
	3895 Hz			X	8717 Hz	
	3896 Hz			X	8921 Hz	
	3960 Hz			X	8930 Hz	
	3961 Hz			X	8966 Hz	
	4238 Hz		X		9034 Hz	
	4310 Hz		X		9058 Hz	
	4446 Hz		X		9699 Hz	

Elde edilen öznetelikler ve eğitim verisi ile eğitilmiş YSA, 50 adetlik test verisi üzerinde parça kalite durumunu değerlendirmek üzere çalıştırılmıştır. Elde edilen sonuçlar belirlenen performans değerleri bazında karşılaştırılmalı olarak Şekil 4.5’de verilmiştir.

		GERÇEK								
		OK	NOK							
ÇIKTI	OK	114	1	115						
	NOK	1	45	46						
		115	46	161						
		<table border="1"> <tr> <td>Özgüllük</td> <td>98%</td> </tr> <tr> <td>Duyarlılık</td> <td>99%</td> </tr> <tr> <td>Doğruluk</td> <td>99%</td> </tr> </table>		Özgüllük	98%	Duyarlılık	99%	Doğruluk	99%	
Özgüllük	98%									
Duyarlılık	99%									
Doğruluk	99%									
		EĞİTİM								

		GERÇEK								
		OK	NOK							
ÇIKTI	OK	16	0	16						
	NOK	2	32	34						
		18	32	50						
		<table border="1"> <tr> <td>Özgüllük</td> <td>100%</td> </tr> <tr> <td>Duyarlılık</td> <td>89%</td> </tr> <tr> <td>Doğruluk</td> <td>96%</td> </tr> </table>		Özgüllük	100%	Duyarlılık	89%	Doğruluk	96%	
Özgüllük	100%									
Duyarlılık	89%									
Doğruluk	96%									
		TEST								

Şekil 4.5. Eğitim ve Test Çalıştırmaları sonucu Karışıklık matrisleri ve Performans

Çalışmada amaçlanan hedefe ulaşıldığı söylenebilir. Parametrik ses kalite kontrol sistemi ile karşılaştırıldığında YSA ile eğitilmiş sistemin, hız sorunu yaşamadan, parametrik sistemin yerini alabileceği öngörülmektedir.

		GERÇEK								
		OK	NOK							
ÇIKTI	OK	58	2	60						
	NOK	35	5	40						
		93	7	100						
		<table border="1"> <tr> <td>Kesinlik</td> <td>71%</td> </tr> <tr> <td>Duyarlılık</td> <td>62%</td> </tr> <tr> <td>Doğruluk</td> <td>63%</td> </tr> </table>		Kesinlik	71%	Duyarlılık	62%	Doğruluk	63%	
Kesinlik	71%									
Duyarlılık	62%									
Doğruluk	63%									
		PARAMETRİK SİSTEM								

		GERÇEK								
		OK	NOK							
ÇIKTI	OK	16	0	16						
	NOK	2	32	34						
		18	32	50						
		<table border="1"> <tr> <td>Özgüllük</td> <td>100%</td> </tr> <tr> <td>Duyarlılık</td> <td>89%</td> </tr> <tr> <td>Doğruluk</td> <td>96%</td> </tr> </table>		Özgüllük	100%	Duyarlılık	89%	Doğruluk	96%	
Özgüllük	100%									
Duyarlılık	89%									
Doğruluk	96%									
		YSA								

Şekil 4.6. Parametrik Sistem ile YSA Performans Karşılaştırma Tablosu

5. TARTIŞMA ve SONUÇ

Bir kalite kontrol sürecindeki verimsizliđi ortadan kaldırmak için başlanan bu çalışmada makine öğrenmesinin iyi bilinen yöntemleri kullanılmıştır. Kalite kontrolü yapılan motorlu ayna katlama mekanizmasına sahip ürünün operasyonel gürültüsünün ses kayıtlarına önışlem uygulandıktan sonra zaman ve frekans uzayında çok sayıda öznitelik üretilmiştir. Üretilen öznitelikler arasından kalite kontrole katkı sağlamak üzere istatistiksel olarak anlamlı olanları seçilerek, 65 adede indirilmiştir. Çok katmanlı, ileri beslemeli bir Yapay Sinir Ađı oluşturularak, eldeki 161 adetlik eğitim verisi ile eğitim, test ve geçernleme aşamaları gerçekleştirilmiştir. Bu şekilde eğitilen YSA seçilen öznitelikleri için hesaplanmış 50 adet yeni test verisi ile tekrar çalıştırılmıştır. Geliştirilen bir program, açma ve kapama şeklinde ikiye bölünmüş ses kayıtlarının sonuçlarını birleştirerek ayna katlama mekanizmasının kalite durumuna ait bir sonuç üretmektedir.

Test sonuçları mevcut durumda kullanılmakta olan Parametrik Sisteme göre ciddi bir iyileştirmeye işaret etmektedir (Şekil 4.6). Yapılan bu tez çalışması ile ortaya konan sonuçlara bakıldığında, bu son derece özel problemi çözmekte başarılı olduğu söylenebilir; çünkü şu anda çalışmakta olan parametrik ses kalitesi ölçme sisteminden çok daha doğru, çok daha duyarlı ve Tip1 hataya kapalı olduğu görölmektedir.

Bundan sonra sistemi uygulamaya almak için işletmede parametrik sistemin ve yeni geliştirilen sistemin eğitim modunda paralel olarak çalıştırılması gerekmektedir. Eğitim modu her ses verisi için bir tahmin yapıldıktan sonra sisteme geri bildirim verilmesi ve hataya göre YSA'nın ağırlıklarının tekrar tekrar düzeltilmesi anlamına gelmektedir. İşletmede sistemin kullanılabilmesi için yönetimin belirleyeceği belli bir süre veya sayıda değerlendirmeyi başarı ile (%95 üzeri doğruluk ve sıfır Tip 1 hata) yapması gerekmektedir.

Bu tez çalışmasının devamı olarak yapılabilecek bir çalışmada çok katmanlı CNN (Evrışimsel Yapay Sinir ađlı) kullanımı ile burada elde edilen sonuçların daha da iyileştirilebileceđi öngörülmektedir.

KAYNAKLAR

- Abu-Mostafa, Y. (2012, Mayıs 6).** Neural Networks. *Lecture 10 of 18 of Caltech's Machine Learning Course- CS 156* [Video]. Erişim adresi: <https://www.youtube.com/watch?v=Ih5Mr93E-2c&t=4204s>
- Bottou, L. (2010).** Proceedings of COMPSTAT'2010. *Proceedings of COMPSTAT'2010*, 177–186. <https://doi.org/10.1007/978-3-7908-2604-3>
- Dhanalakshmi, P., Palanivel, S., & Ramalingam, V. (2009).** Classification of audio signals using SVM and RBFNN. *Expert Systems with Applications*, 36(3 PART 2), 6069–6075. <https://doi.org/10.1016/j.eswa.2008.06.126>
- Elliott, S. J. (2010).** Active noise and vibration control in vehicles. *Vehicle Noise and Vibration Refinement*. <https://doi.org/10.1533/9781845698041.3.235>
- Emel, E., & Kannatey-Asibu, E. (1989).** Acoustic emission and force sensor fusion for monitoring the cutting process. *International Journal of Mechanical Sciences*, 31(11–12), 795–809. [https://doi.org/10.1016/0020-7403\(89\)90025-8](https://doi.org/10.1016/0020-7403(89)90025-8)
- Harris, C. M., & Tocci, G. C. (1993).** Handbook of Acoustical Measurements and Noise Control. *The Journal of the Acoustical Society of America* (C. 93, Sayı 6). <https://doi.org/10.1121/1.405398>
- Isermann, R. (2006).** Fault-Diagnosis Systems. *Fault-Diagnosis Systems*. <https://doi.org/10.1007/3-540-30368-5>
- Jin, X., Zhao, M., Chow, T. W. S., & Pecht, M. (2014).** Motor bearing fault diagnosis using trace ratio linear discriminant analysis. *IEEE Transactions on Industrial Electronics*, 61(5), 2441–2451. <https://doi.org/10.1109/TIE.2013.2273471>
- Joly, A., Goeau, H., Botella, C., Glotin, H., Bonnet, P., Vellinga, W.-P., Planque, R., & Müller, H. (2018).** *Overview of LifeCLEF 2018: a Large-scale Evaluation of Spices Identification and Recommendation Algorithms in the ERA of AI* (s. 21).
- Kaya, İ., Oktay, S., & Engin, O. (2005).** Kalite kontrol problemlerinin çözümünde Yapay Sinir Ağlarının kullanımı. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21, 92–107.
- Lüke, D. (1999).** Origins of the sampling theorem. *IEEE Communications Magazine*, 37(4), 106–108. <https://doi.org/10.1109/35.755459>
- Mathews, M. (1999).** Mathews-Pierce_1-10_89-103.pdf. *The Ear and How It Works* (ss. 1–10).
- Roberts, S. (2003).** Lecture 7 - The Discrete Fourier Transform. *The Discrete Fourier Transform*, 82–96. <https://doi.org/10.1142/4610>
- Sarti, A. (2017, Haziran 6).** Elements of psychoacoustics. *A lesson of the course of "Sound analysis, synthesis and processing" by professor Augusto Sarti* [Video]. Erişim adresi https://www.youtube.com/watch?v=coxulY_y9cA&t=1597s

- Shimamura, T., & Kobayashi, H. (2001).** Weighted autocorrelation for pitch extraction of noisy speech. *IEEE Transactions on Speech and Audio Processing*, 9(7), 727–730. <https://doi.org/10.1109/89.952490>
- Stocia, P., & Moses, R. (2005).** Spectral Analysis of Signals. *Prentice Hall, Upper Saddle River, New Jersey 07458* (C. 24, Sayı 1).
<https://doi.org/10.1109/msp.2007.273066>
- Svozil, D., Kvasnieka, V., & Pospichal, J. (1997).** *Introduction to multi-layer feed-forward neural networks*. 39, 43–62.
- Volandri, G., Di Puccio, F., Forte, P., & Mattei, L. (2018).** Psychoacoustic analysis of power windows sounds: Correlation between subjective and objective evaluations. *Applied Acoustics*, 134(May), 160–170.
<https://doi.org/10.1016/j.apacoust.2017.11.020>
- Wang, X., & Subic, A. (2011).** *Psychoacoustic modelling of vehicle side mirror power-fold actuator noise characteristics*. 1996(June).
<https://doi.org/10.1177/0954406211399514>
- Yang, W., Wang, K., & Zuo, W. (2012).** Neighborhood component feature selection for high-dimensional data. *Journal of Computers*, 7(1), 162–168.
<https://doi.org/10.4304/jcp.7.1.161-168>
- Zhang, H.-C., & Huang, S. H. (1995).** Applications of neural networks in manufacturing: a state-of-the-art survey. *The International Journal Of Production Research*, 33(3), 705–728.

EKLER

- EK 1** Test ve Validasyon dosyaları kalite durumunu gösterir tablo
- EK 2** Seçilmiş ve Hesaplanmış Girdilerin Tamamı
- EK 3** Çalışma İçin Geliştirilen Programlar
- EK 4** Temiz Oda Sınıflandırmaları

EK 1

Test ve Validasyon dosyaları kalite durumunu gösterir tablo

YAPAY SINIR AĞI EĞİTİM, VALIDASYON VE TEST İÇİN KULLANILAN 161 SES DOSYASININ KALİTE DURUMLARINI GÖSTERİR TABLO

DOSYA	DRIVE TO PARK						PARK TO DRIVE						SONUÇ	
	OK	HATA1	HATA2	HATA3	HATA4	HATA5	OK	HATA1	HATA2	HATA3	HATA4	HATA5		
1 Sample1.wav	0	1	0	0	0	0	0	0	0	1	0	0	0	NOT OK
2 Sample2.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
3 Sample3.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
4 Sample4.wav	1	0	0	0	0	0	0	0	0	0	1	0	0	NOT OK
5 Sample5.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
6 Sample6.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
7 Sample7.wav	0	0	0	1	0	0	0	1	0	0	0	0	0	NOT OK
8 Sample8.wav	1	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
9 Sample9.wav	0	0	0	0	1	0	1	0	0	0	0	0	0	NOT OK
10 Sample10.wav	0	0	0	1	0	0	0	1	0	0	0	0	0	NOT OK
11 Sample11.wav	0	1	0	0	0	0	1	0	0	0	0	0	0	NOT OK
12 Sample12.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
13 Sample13.wav	1	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
14 Sample14.wav	0	0	0	1	0	0	1	0	0	0	0	0	0	NOT OK
15 Sample15.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
16 Sample16.wav	1	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
17 Sample17.wav	1	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
18 Sample18.wav	1	0	0	0	0	0	0	0	0	0	1	0	0	NOT OK
19 Sample19.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
20 Sample20.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
21 Sample21.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
22 Sample22.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
23 Sample23.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
24 Sample24.wav	1	0	0	0	0	0	0	0	0	0	1	0	0	NOT OK
25 Sample25.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
26 Sample26.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
27 Sample27.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
28 Sample28.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
29 Sample29.wav	1	0	0	0	0	0	0	0	0	1	0	0	0	NOT OK
30 Sample30.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
31 Sample31.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
32 Sample32.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
33 Sample33.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
34 Sample34.wav	1	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
35 Sample35.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
36 Sample36.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
37 Sample37.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
38 Sample38.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
39 Sample39.wav	1	0	0	0	0	0	0	0	1	0	0	0	0	NOT OK
40 Sample40.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
41 Sample41.wav	0	0	0	0	0	1	0	0	0	0	0	1	0	NOT OK
42 Sample42.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
43 Sample43.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
44 Sample44.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
45 Sample45.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
46 Sample46.wav	0	0	1	0	0	0	1	0	0	0	0	0	0	NOT OK
47 Sample47.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
48 Sample48.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
49 Sample49.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
50 Sample50.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
51 Sample51.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
52 Sample52.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
53 Sample53.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
54 Sample54.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
55 Sample55.wav	1	0	0	0	0	0	0	0	0	1	0	0	0	NOT OK
56 Sample56.wav	1	0	0	0	0	0	0	0	0	0	0	1	0	NOT OK
57 Sample57.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
58 Sample58.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
59 Sample59.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK
60 Sample60.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	OK

EK 1

Test ve Validasyon dosyaları kalite durumunu gösterir tablo (Devamı)

DOSYA	DRIVE TO PARK						PARK TO DRIVE						SONUÇ
	OK	HATA1	HATA2	HATA3	HATA4	HATA5	OK	HATA1	HATA2	HATA3	HATA4	HATA5	
61 Sample61.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
62 Sample62.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
63 Sample63.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
64 Sample64.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
65 Sample65.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
66 Sample66.wav	1	0	0	0	0	0	0	0	0	0	1	0	0 NOT OK
67 Sample67.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
68 Sample68.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
69 Sample69.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
70 Sample70.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
71 Sample71.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
72 Sample72.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
73 Sample73.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
74 Sample74.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
75 Sample75.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
76 Sample76.wav	1	0	0	0	0	0	0	0	0	1	0	0	0 NOT OK
77 Sample77.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
78 Sample78.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
79 Sample79.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
80 Sample80.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
81 Sample81.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
82 Sample82.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
83 Sample83.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
84 Sample84.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
85 Sample85.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
86 Sample86.wav	1	0	0	0	0	0	0	0	1	0	0	0	0 NOT OK
87 Sample87.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
88 Sample88.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
89 Sample89.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
90 Sample90.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
91 Sample91.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
92 Sample92.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
93 Sample93.wav	0	1	0	0	0	0	1	0	0	0	0	0	0 NOT OK
94 Sample94.wav	1	0	0	0	0	0	0	0	0	0	1	0	0 NOT OK
95 Sample95.wav	1	0	0	0	0	0	0	0	0	1	0	0	0 NOT OK
96 Sample96.wav	1	0	0	0	0	0	0	1	0	0	0	0	0 NOT OK
97 Sample97.wav	1	0	0	0	0	0	0	0	0	1	0	0	0 NOT OK
98 Sample98.wav	1	0	0	0	0	0	0	0	0	0	1	0	0 NOT OK
99 Sample99.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
100 Sample100.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
101 Sample101.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
102 Sample102.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
103 Sample103.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
104 Sample104.wav	1	0	0	0	0	0	0	0	0	0	1	0	0 NOT OK
105 Sample105.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
106 Sample106.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
107 Sample107.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
108 Sample108.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
109 Sample109.wav	0	0	0	0	1	0	1	0	0	0	0	0	0 NOT OK
110 Sample110.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
111 Sample111.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
112 Sample112.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
113 Sample113.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
114 Sample114.wav	0	0	0	0	0	1	0	0	0	0	0	1	0 NOT OK
115 Sample115.wav	0	0	0	1	0	0	1	0	0	0	0	0	0 NOT OK
116 Sample116.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
117 Sample117.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
118 Sample118.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
119 Sample119.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
120 Sample120.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK

EK 1 Test ve Validasyon dosyaları kalite durumunu gösterir tablo (Devamı)

DOSYA	DRIVE TO PARK						PARK TO DRIVE						SONUÇ
	OK	HATA1	HATA2	HATA3	HATA4	HATA5	OK	HATA1	HATA2	HATA3	HATA4	HATA5	
121 Sample121.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
122 Sample122.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
123 Sample123.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
124 Sample124.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
125 Sample125.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
126 Sample126.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
127 Sample127.wav	1	0	0	0	0	0	0	1	0	0	0	0	0 NOT OK
128 Sample128.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
129 Sample129.wav	0	0	0	0	1	0	1	0	0	0	0	0	0 NOT OK
130 Sample130.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
131 Sample131.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
132 Sample132.wav	0	0	0	0	1	0	1	0	0	0	0	0	0 NOT OK
133 Sample133.wav	1	0	0	0	0	0	0	1	0	0	0	0	0 NOT OK
134 Sample134.wav	1	0	0	0	0	0	0	1	0	0	0	0	0 NOT OK
135 Sample135.wav	1	0	0	0	0	0	0	1	0	0	0	0	0 NOT OK
136 Sample136.wav	1	0	0	0	0	0	0	1	0	0	0	0	0 NOT OK
137 Sample137.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
138 Sample138.wav	1	0	0	0	0	0	0	0	0	0	1	0	0 NOT OK
139 Sample139.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
140 Sample140.wav	1	0	0	0	0	0	0	1	0	0	0	0	0 NOT OK
141 Sample141.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
142 Sample142.wav	0	0	0	0	1	0	1	0	0	0	0	0	0 NOT OK
143 Sample143.wav	1	0	0	0	0	0	0	1	0	0	0	0	0 NOT OK
144 Sample144.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
145 Sample145.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
146 Sample146.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
147 Sample147.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
148 Sample148.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
149 Sample149.wav	1	0	0	0	0	0	0	0	0	0	1	0	0 NOT OK
150 Sample150.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
151 Sample151.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
152 Sample152.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
153 Sample153.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
154 Sample154.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
155 Sample155.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
156 Sample156.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
157 Sample157.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
158 Sample158.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
159 Sample159.wav	1	0	0	0	0	0	0	0	1	0	0	0	0 NOT OK
160 Sample160.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK
161 Sample161.wav	1	0	0	0	0	0	1	0	0	0	0	0	1 OK

EK 1 Test ve Validasyon dosyaları kalite durumunu gösterir tablo (Devamı)

YAPAY SINIR AĞI TEST İÇİN KULLANILAN 50 SES DOSYASININ KALİTE DURUMLARINI GÖSTERİR TABLO

DOSYA	DRIVE TO PARK						PARK TO DRIVE						SONUÇ		
	OK	HATA1	HATA2	HATA3	HATA4	HATA5	OK	HATA1	HATA2	HATA3	HATA4	HATA5			
1 EKSES1.wav	1	0	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
2 EKSES2.wav	0	0	0	1	0	0	0	0	1	0	0	0	0	0	NOT OK
3 EKSES3.wav	0	0	0	1	0	0	0	1	0	0	0	0	0	0	NOT OK
4 EKSES4.wav	0	0	0	1	0	0	0	1	0	0	0	0	0	0	NOT OK
5 EKSES5.wav	0	0	0	1	0	0	0	1	0	0	0	0	0	0	NOT OK
6 EKSES6.wav	0	0	0	1	0	0	0	1	0	0	0	0	0	0	NOT OK
7 EKSES7.wav	0	0	0	1	0	0	0	0	0	0	1	0	0	0	NOT OK
8 EKSES8.wav	0	0	0	1	0	0	1	0	0	0	0	0	0	0	NOT OK
9 EKSES9.wav	0	0	0	1	0	0	1	0	0	0	0	0	0	0	NOT OK
10 EKSES10.wav	0	0	0	1	0	0	1	0	0	0	0	0	0	0	NOT OK
11 EKSES11.wav	0	0	0	1	0	0	1	0	0	0	0	0	0	0	NOT OK
12 EKSES12.wav	1	0	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
13 EKSES13.wav	1	0	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
14 EKSES14.wav	1	0	0	0	0	0	0	0	0	1	0	0	0	0	NOT OK
15 EKSES15.wav	1	0	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
16 EKSES16.wav	1	0	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
17 EKSES17.wav	1	0	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
18 EKSES18.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
19 EKSES19.wav	0	0	0	1	0	0	0	1	0	0	0	0	0	0	NOT OK
20 EKSES20.wav	0	0	0	1	0	0	0	0	0	0	1	0	0	0	NOT OK
21 EKSES21.wav	1	0	0	0	0	0	0	0	1	0	0	0	0	0	NOT OK
22 EKSES22.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
23 EKSES23.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
24 EKSES24.wav	0	0	0	1	0	0	1	0	0	0	0	0	0	0	NOT OK
25 EKSES25.wav	1	0	0	0	0	0	0	0	0	0	1	0	0	0	NOT OK
26 EKSES26.wav	0	0	0	0	0	1	1	0	0	0	0	0	0	0	NOT OK
27 EKSES27.wav	0	0	0	1	0	0	1	0	0	0	0	0	0	0	NOT OK
28 EKSES28.wav	1	0	0	0	0	0	0	1	0	0	0	0	0	0	NOT OK
29 EKSES29.wav	1	0	0	0	0	0	0	1	0	0	0	0	0	0	NOT OK
30 EKSES30.wav	0	0	0	0	1	0	1	0	0	0	0	0	0	0	NOT OK
31 EKSES31.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
32 EKSES32.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
33 EKSES33.wav	1	0	0	0	0	0	0	1	0	0	0	0	0	0	NOT OK
34 EKSES34.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
35 EKSES35.wav	1	0	0	0	0	0	0	0	0	1	0	0	0	0	NOT OK
36 EKSES36.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
37 EKSES37.wav	0	0	0	0	1	0	0	1	0	0	0	0	0	0	NOT OK
38 EKSES38.wav	1	0	0	0	0	0	0	0	0	1	0	0	0	0	NOT OK
39 EKSES39.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
40 EKSES40.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
41 EKSES41.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
42 EKSES42.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
43 EKSES43.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
44 EKSES44.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
45 EKSES45.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
46 EKSES46.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
47 EKSES47.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
48 EKSES48.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK
49 EKSES49.wav	0	0	0	0	0	1	0	0	0	0	0	0	1	0	NOT OK
50 EKSES50.wav	1	0	0	0	0	0	1	0	0	0	0	0	0	0	OK

EK 2 Seçilmiş ve Hesaplanmış Girdiler

DTP GİRDİLER	Freq: 2	Freq: 9699	Max dB	Avg dB	Delta dB Max	Delta dB Avg	AUTOCORR PEAK @0	AUTOCORR PEAK @1	AUTOCORR PEAK @2	MINIMUM POWER	STD DEV	PEAK	SKEWNESS	KURTOSIS	SHAPE FACTOR
Sample1.wav	413.3	251.3	0.907	18.08	76.23	73.95	4.845	4.317	1229	235.5	139.3	558	0.148	0.747	-0.07	3.895	2.72E-10
Sample2.wav	243.3	91.53	3.896	4.288	67.36	65.75	3.325	2.85	764.2	362.9	232.2	2223	0.111	0.424	-0.03	2.84	2.77E-10
Sample3.wav	587.9	323.8	3.265	18.4	68.16	66.26	4.589	3.553	1372	742.2	565.5	3343	0.136	0.586	0.65	3.604	2.59E-10
Sample4.wav	633.7	42.3	3.946	23.29	72.94	70.45	3.01	3.711	1306	629.6	546.1	198	0.146	0.927	0.411	3.726	2.75E-10
Sample5.wav	319.5	142.3	1.147	13.43	68.19	66.58	2.296	1.955	770.3	222.8	88.06	616	0.118	0.568	0.047	3.708	2.71E-10
...																	
Sample160.wav	973.2	130.8	4.49	7.202	67.38	65.38	0.89	1.145	3304	2726	2304	2550	0.225	0.847	0.128	2.511	2.79E-10
Sample161.wav	174	279.8	1.834	1.512	68.31	67.03	2.248	0.074	2375	1908	1768	3441	0.206	0.635	-0.02	2.252	2.86E-10

Not : Çizelge sayfaya sığdırabilmek amacı ile kısaltılmış olup Çizelge 4.1'te belirlenen özniteliklerin tam listesi CD'de mevcuttur.

EK 3 Program Kodu

1. Öncelikle tüm girdiler hesaplanmalıdır (TUM_OZELLIKLER_son.m) :

```
% Bu Matlab Programı İsmail TEPEDAĞ tarafından yazılmıştır.
% Her Hakkı Mahfuzdur. 2020
% Tüm olası Zaman ve Frekans Uzayı Girdileri Hesaplanır. NCA için.
clc;
close all;
clearvars; % this group is to make a fresh start in memory

addpath('D:\MyMatlabScripts'); % Location of Sound Sample.wav Files
addpath('D:\Users\İsmail\Documents\!TEZ\Test Files\Test1'); % Only TEst
addpath('D:\Users\İsmail\Documents\MATLAB\SignalProcessingAndMachineLearningF
orSensorDataAnalytic');
addpath('C:\Users\HP\Documents\MATLAB\TEZ'); % TEZ
% Learning Data
numfiles = 161; % Total number of sound files
ts=1/44100;
%numtest=46; % Test yapılacak ses dosyaları

for fileidx3 = 1:numfiles % for each sound file from 1 to number of files
    gecici=fileidx3
    MasterDosya=sprintf('Sample%d.wav', fileidx3); % Create file name to read
    [Master,Fs]=audioread(MasterDosya); % Read audio file + Sampling Rate Fs
    [DtP,PtD]=sesbolme(Master); % Main sound file divided into 2 sections
closing/opening
    [FeaturesDE,FeaturesPE]=FULLFE_son(DtP,PtD,fileidx3);
    FeaturesD(fileidx3,:)=FeaturesDE(fileidx3,:);
    FeaturesP(fileidx3,:)=FeaturesPE(fileidx3,:);
end
```

2. NCA ile Öznitelik Seçimi yapılır (NCA.m)

```
% nca classification obs(parametreler) ve grp(beklenen sonuç) değişkenlerini
manuel yükleyin
% observations
% obsD=0; save obsD;// load obsD; obs=obsD; clear obsD; // normalized
% obsF=0; save obsF;// load obsF; obs=obsF; clear obsF;// normalized
rng(1); % For reproducibility
cvp = cvpartition(grp,'holdout',40); % orijinal 40 was 0.1
Xtrain = obs(cvp.training,:);
ytrain = grp(cvp.training,:);
Xtest = obs(cvp.test,:);
ytest = grp(cvp.test,:);
% Compute generalization error without fitting.
snca = fscnca(Xtrain,ytrain,'FitMethod','none');
L = loss(snca,Xtest,ytest);
% Fit NCA without regularization parameter (Lambda = 0)
snca = fscnca(Xtrain,ytrain,'FitMethod','exact','Lambda',0,...
'Solver','sgd','Standardize',true);
L = loss(snca,Xtest,ytest);
% Tune the regularization parameter for NCA using five-fold cross-validation
% 1. Partition the training data into five folds and extract the number of
validation (test) sets. For each fold, cvpartition assigns four-fifths of the
data as a training set, and one-fifth of the data as a test set.
```



```

cvp = cvpartition(ytrain,'kfold',5);
numvalidsets = cvp.NumTestSets;

% Assign  $\lambda$  values and create an array to store the loss function values.

n = length(ytrain);
lambdaval = linspace(0,20,20)/n;
lossvals = zeros(length(lambdaval),numvalidsets);

%2. Train the NCA model for each  $\lambda$  value, using the training set in each
fold.
%3. Compute the classification loss for the corresponding test set in the
fold using the NCA model. Record the loss value.
%4. Repeat this process for all folds and all  $\lambda$  values.

for i = 1:length(lambdaval)
    for k = 1:numvalidsets
        X = Xtrain(cvp.training(k),:);
        y = ytrain(cvp.training(k),:);
        Xvalid = Xtrain(cvp.test(k),:);
        yvalid = ytrain(cvp.test(k),:);

        snca = fscnca(X,y,'FitMethod','exact', ...
            'Solver','sgd','Lambda',lambdaval(i), ...
            'IterationLimit',30,'GradientTolerance',1e-4, ...
            'Standardize',true);

        lossvals(i,k) =
loss(snca,Xvalid,yvalid,'LossFunction','classiferror');
    end
end

% Compute the average loss obtained from the folds for each  $\lambda$  value.
meanloss = mean(lossvals,2);
figure()
plot(lambdaval,meanloss,'ro-')
xlabel('Lambda')
ylabel('Loss (MSE)')
grid on

[~,idx] = min(meanloss) % Find the index
bestlambda = lambdaval(idx) % Find the best lambda value
bestloss = meanloss(idx)
% Fit the nca model on all data using best  $\lambda$  and plot the feature weights
snca = fscnca(Xtrain,ytrain,'FitMethod','exact','Solver','sgd',...
    'Lambda',bestlambda,'Standardize',true,'Verbose',1);
% Plot
figure()
plot(snca.FeatureWeights,'ro')
xlabel('Feature index')
ylabel('Feature weight')
grid on
% Select features using the feature weights and a relative threshold.
tol = 0.01;
selidx = find(snca.FeatureWeights > tol*max(1,max(snca.FeatureWeights)))

```

```

% Compute the classification loss using the test set.
L = loss(snca,Xtest,ytest)
% Classify observations using the selected features
features = Xtrain(:,selidx);
svmMdl = fitcecoc(features,ytrain);
L = loss(svmMdl,Xtest(:,selidx),ytest)

```

3. Seçilmiş Öznitelikler ile eğitim grubu için Öznitelik Üretimi (TezStepFinalafterNCA.m /Bölüm 1/)

```

% Final - Total Program : TezStepFinal
%

```

```

clc;
close all;
clearvars; % this group is to make a fresh start in memory

```

```

addpath('D:\MyMatlabScripts\DataSet'); % Location of Sound Sample.wav Files
addpath('D:\Users\İsmail\Documents\!TEZ\Test Files\Test1'); % Only TEst
addpath('D:\Users\İsmail\Documents\MATLAB\SignalProcessingAndMachineLearningF
orSensorDataAnalytic');
addpath('C:\Users\HP\Documents\MATLAB\TEZ'); % TEZ
% Learning Data
numfiles = 161; % Total number of sound files
ts=1/44100;

```

```

for fileidx3 = 1:numfiles % for each sound file from 1 to number of files
    gecici=fileidx3
    MasterDosya=sprintf('Sample%d.wav', fileidx3); % Create file name to read
    [Master,Fs]=audioread(MasterDosya); % Read audio file + Sampling Rate Fs
    [DtP,PtD]=sesbolme(Master); % Main sound file divided into 2 sections
closing/opening
    [FeaturesDE,FeaturesPE]=SelectiveFeatureExtract(DtP,PtD,fileidx3);
    FeaturesD(fileidx3,:)=FeaturesDE(fileidx3,:);
    FeaturesP(fileidx3,:)=FeaturesPE(fileidx3,:);
    PtDx(fileidx3,:)=PtD;
    DtPx(fileidx3,:)=DtP;
end
for i=1:numfiles
    % Time Dimension Features PtD
    Toplam1=0;
    Toplam2=0;
    Toplam3=0;
    Toplam4=0;
    Toplam5=0;
    Toplam6=0;
    Toplam7=1;
    StdDevx=0;
    Skewnesss=0;
    Kurtosiss=0;
    Crest_Factor=0;
    Clearance_Factor=0;
    Shape_Factor=0;
    Impact_Factor=0;
    SMR=0;

```

```

Peak=0;
for j=1:length(PtDx)
    Toplam1=Toplam1+PtDx(i,j);
    Toplam7=Toplam7+abs(PtDx(i,j));
    Ortalama1=Toplam1/length(PtDx);
    Toplam2=Toplam2+PtDx(i,j)^2;
    Toplam6=Toplam6+sqrt(abs(PtDx(i,j)));
    Ortalama2=Toplam2/length(PtDx);
    RMS=sqrt(Ortalama2);
    Peak=max(Peak,abs(PtDx(i,j))); % 2.
end
SMR=(Toplam6/length(PtDx))^2; %9
Shape_Factor=SMR/Toplam7/length(PtDx);%7
Impact_Factor=Peak/Toplam7/length(PtDx);%8
Toplam3=0.00001;
for j=1:length(PtDx)
    Toplam3=Toplam3+(PtDx(i,j)-Ortalama1)^2;
    Toplam4=Toplam4+(PtDx(i,j)-Ortalama1)^3;
    Toplam5=Toplam5+(PtDx(i,j)-Ortalama1)^4;
end
StdDevx=sqrt(Toplam3/length(PtDx));% 1.
StdDevy=StdDevx^3;
StdDevz=StdDevx^4;
Skewnesss=Toplam4/(length(PtDx)*StdDevy); %3
Kurtosiss=Toplam5/(length(PtDx)*StdDevz); %4
Crest_Factor=Peak/RMS; %5
Clearance_Factor=Peak/SMR; %6

FeaturesP(i,61)=StdDevx; %NCA
FeaturesP(i,62)=Peak; %NCA
FeaturesP(i,63)=Skewnesss;%NCA
FeaturesP(i,64)=Kurtosiss;%NCA
%FeaturesP(i,70)=Crest_Factor;
%FeaturesP(i,71)=Clearance_Factor;
FeaturesP(i,65)=Shape_Factor;%NCA
%FeaturesP(i,73)=Impact_Factor;
%FeaturesP(i,74)=SMR;

```

% Time Dimension Features DtP

```

Toplam1=0;
Toplam2=0;
Toplam3=0;
Toplam4=0;
Toplam5=0;
Toplam6=0;
Toplam7=1;
StdDevx=0;
Skewnesss=0;
Kurtosiss=0;
Crest_Factor=0;
Clearance_Factor=0;
Shape_Factor=0;
Impact_Factor=0;
SMR=0;
Peak=0;

```

```

for j=1:length(DtPx)
    Toplam1=Toplam1+DtPx(i,j);
    Toplam7=Toplam7+abs(DtPx(i,j));
    Toplam2=Toplam2+DtPx(i,j)^2;
    Toplam6=Toplam6+sqrt(abs(DtPx(i,j)));
    Peak=max(Peak,abs(DtPx(i,j))); % 2.
end
Ortalama1=Toplam1/length(DtPx);
Ortalama2=Toplam2/length(DtPx);
RMS=sqrt(Ortalama2);
SMR=(Toplam6/length(DtPx))^2; %9
Shape_Factor=SMR/Toplam7/length(DtPx);%7
Impact_Factor=Peak/Toplam7/length(DtPx);%8
Toplam3=0.0001;
for j=1:length(DtPx)
    Toplam3=Toplam3+(DtPx(i,j)-Ortalama1)^2;
    Toplam4=Toplam4+(DtPx(i,j)-Ortalama1)^3;
    Toplam5=Toplam5+(DtPx(i,j)-Ortalama1)^4;
end
StdDevx=sqrt(Toplam3/length(DtPx));% 1.
StdDevy=StdDevx^3;
StdDevz=StdDevx^4;
Skewnesss=Toplam4/(length(DtPx)*StdDevy); %3
Kurtosiss=Toplam5/(length(DtPx)*StdDevz); %4
Crest_Factor=Peak/RMS; %5
Clearance_Factor=Peak/SMR; %6

FeaturesD(i,61)=StdDevx;
FeaturesD(i,62)=Peak;
FeaturesD(i,63)=Skewnesss;
FeaturesD(i,64)=Kurtosiss;
%FeaturesD(i,70)=Crest_Factor;
%FeaturesD(i,71)=Clearance_Factor;
FeaturesD(i,65)=Shape_Factor;
%FeaturesD(i,73)=Impact_Factor;
%FeaturesD(i,74)=SMR;

end

```

4. YSA oluşturma ve Eğitim (TezStepFinalafterNCA.m /Bölüm 2/)

```

%% %%% All features has been produced %%%
%load DtPOuts=0; % Beklenen Çıktıları manuel yükleyin ya da önceki bir
%dosyadan geri çağırın
%load PtDOuts=0;

DtPIn=FeaturesD(:,:); %YSA Hazırlık / Girdiler
PtDIn=FeaturesP(:,:); %
DtPOutF=DtPOuts(:,:);
PtDOutF=PtDOuts(:,:);

netDtP=patternnet([24 18 12]);
netDtP = configure(netDtP,DtPIn',DtPOutF');
%view(netDtP) % DtP için YSA oluştur ve göster

```

```

netPtD=patternnet([24 18 12]);
netPtD = configure(netPtD,PtDIn',PtDOutF');
%view(netPtD) % PtD için YSA oluştur ve göster

for s=1:100
    [netDtP, trD] = train(netDtP,DtPIn',DtPOutF');
    % Tekrarlı eğitim ****
end

for t=1:100
    [netPtD, trP]= train(netPtD,PtDIn',PtDOutF');
    % Tekrarlı eğitim ****
end

%save('FinalYSABitis');
%load ('FinalYSABitis');
%Eğitim Bitti

% 161 örneklik grubun değerlendirmesi
yDtP=netDtP(DtPIn');
yPtD=netPtD(PtDIn');

for i=1:length(yDtP)
    pass=0;
    [M, I] = max(yDtP(:,i));
    [M2, I3]=max(yDtP(2:6,i));
    if M2>0.3999
        NNResult(i,:)=[0 0 0 0 0 0];
        NNResult(i,I3+1)=1;
        pass=1;
    end
    if pass==0
        if I==1
            if M>0.4999
                NNResult(i,:)=[1 0 0 0 0 0];
            else
                [secondd, I2]=max(yDtP(2:6,i));
                NNResult(i,:)=[0 0 0 0 0 0];
                NNResult(i,I2+1)=1;
            end
        else
            NNResult(i,:)=[0 0 0 0 0 0];
            NNResult(i,I)=1;
        end
    end
end

for i=1:length(yPtD)
    pass=0;
    [M, I] = max(yPtD(:,i));
    [M2, I3]=max(yPtD(2:6,i));
    if M2>0.2320
        NNResultP(i,:)=[0 0 0 0 0 0];
        NNResultP(i,I3+1)=1;
    end
end

```

```

        pass=1;
    end
    if pass==0
    if I==1
        if M>0.4999
            NNResultP(i,:)= [1 0 0 0 0];
        else
            [secondd, I2]=max(yPtD(2:6,i));
            NNResultP(i,:)= [0 0 0 0 0];
            NNResultP(i,I2+1)=1;
        end
    else
        NNResultP(i,:)= [0 0 0 0 0];
        NNResultP(i,I)=1;
    end
end
end

```

5. 50 adetlik TEST verisinin öznitelik hazırlama ve önceden eğitilmiş YSA ile değerlendirilmesi (TezStepFinalafterNCA.m /Bölüm 3/)

```

%% Değerlendirme
% Yeni bir test listesinden öznitelik üretip YSA ile değerlendireceğiz.
% 50 ses dosyası değerlendirilecek
numtest=50; % Test yapılacak ses dosyaları
addpath('D:\MyMatlabScripts\DataSet'); % Location of Sound Sample.wav Files
for fileidx3 = 1:numtest % for each sound file from 1 to number of files
    gecici=fileidx3
    MasterDosya=sprintf('EKSES%d.wav', fileidx3); % Create file name to read
    [Mastert,Fs]=audioread(MasterDosya); % Read audio file + Sampling Rate Fs
    [DtPt,PtDt]=sesbolme(Mastert); % Main sound file divided into 2 sections
closing/opening
    [FeaturesDEt,FeaturesPEt]=SelectiveFeatureExtract(DtPt,PtDt,fileidx3);
    FeaturesDt(fileidx3,:)=FeaturesDEt(fileidx3,:);
    FeaturesPt(fileidx3,:)=FeaturesPEt(fileidx3,:);
    % clear 'FeaturesDt' 'FeaturesPt'
    PtDxt(fileidx3,:)=PtDt;
    DtPxt(fileidx3,:)=DtPt;
end
for i=1:numtest
% Time Dimension Features PtD
    Toplam1=0;
    Toplam2=0;
    Toplam3=0;
    Toplam4=0;
    Toplam5=0;
    Toplam6=0;
    Toplam7=1;
    StdDevx=0;
    Skewnesss=0;
    Kurtosiss=0;
    Crest_Factor=0;
    Clearance_Factor=0;
    Shape_Factor=0;
    Impact_Factor=0;
    SMR=0;

```

```

Peak=0;
for j=1:length(PtDxt)
    Toplam1=Toplam1+PtDxt(i,j);
    Toplam7=Toplam7+abs(PtDxt(i,j));
    Ortalama1=Toplam1/length(PtDxt);
    Toplam2=Toplam2+PtDxt(i,j)^2;
    Toplam6=Toplam6+sqrt(abs(PtDxt(i,j)));
    Ortalama2=Toplam2/length(PtDxt);
    RMS=sqrt(Ortalama2);
    Peak=max(Peak,abs(PtDxt(i,j))); % 2.
end
SMR=(Toplam6/length(PtDxt))^2; %9
Shape_Factor=SMR/Toplam7/length(PtDxt);%7
Impact_Factor=Peak/Toplam7/length(PtDxt);%8
Toplam3=0.00001;
for j=1:length(PtDxt)
    Toplam3=Toplam3+(PtDxt(i,j)-Ortalama1)^2;
    Toplam4=Toplam4+(PtDxt(i,j)-Ortalama1)^3;
    Toplam5=Toplam5+(PtDxt(i,j)-Ortalama1)^4;
end
StdDevx=sqrt(Toplam3/length(PtDxt));% 1.
StdDevy=StdDevx^3;
StdDevz=StdDevx^4;
Skewnesss=Toplam4/(length(PtDxt)*StdDevy); %3
Kurtosiss=Toplam5/(length(PtDxt)*StdDevz); %4
Crest_Factor=Peak/RMS; %5
Clearance_Factor=Peak/SMR; %6

FeaturesPt(i,61)=StdDevx; %NCA
FeaturesPt(i,62)=Peak; %NCA
FeaturesPt(i,63)=Skewnesss;%NCA
FeaturesPt(i,64)=Kurtosiss;%NCA
%FeaturesPt(i,40)=Crest_Factor;
%FeaturesPt(i,71)=Clearance_Factor;
FeaturesPt(i,65)=Shape_Factor;%NCA
%FeaturesPt(i,73)=Impact_Factor;
%FeaturesPt(i,74)=SMR;

```

```
% Time Dimension Features DtP
```

```

Toplam1=0;
Toplam2=0;
Toplam3=0;
Toplam4=0;
Toplam5=0;
Toplam6=0;
Toplam7=1;
StdDevx=0;
Skewnesss=0;
Kurtosiss=0;
Crest_Factor=0;
Clearance_Factor=0;
Shape_Factor=0;
Impact_Factor=0;
SMR=0;

```

```

Peak=0;

for j=1:length(DtPxt)
    Toplam1=Toplam1+DtPxt(i,j);
    Toplam7=Toplam7+abs(DtPxt(i,j));
    Toplam2=Toplam2+DtPxt(i,j)^2;
    Toplam6=Toplam6+sqrt(abs(DtPxt(i,j)));
    Peak=max(Peak,abs(DtPxt(i,j))); % 2.
end
Ortalama1=Toplam1/length(DtPxt);
Ortalama2=Toplam2/length(DtPxt);
RMS=sqrt(Ortalama2);
SMR=(Toplam6/length(DtPxt))^2; %9
Shape_Factor=SMR/Toplam7/length(DtPxt);%7
Impact_Factor=Peak/Toplam7/length(DtPxt);%8
Toplam3=0.0001;
for j=1:length(DtPxt)
    Toplam3=Toplam3+(DtPxt(i,j)-Ortalama1)^2;
    Toplam4=Toplam4+(DtPxt(i,j)-Ortalama1)^3;
    Toplam5=Toplam5+(DtPxt(i,j)-Ortalama1)^4;
end
StdDevx=sqrt(Toplam3/length(DtPxt));% 1.
StdDevy=StdDevx^3;
StdDevz=StdDevx^4;
Skewnesss=Toplam4/(length(DtPxt)*StdDevy); %3
Kurtosiss=Toplam5/(length(DtPxt)*StdDevz); %4
Crest_Factor=Peak/RMS; %5
Clearance_Factor=Peak/SMR; %6

FeaturesDt(i,61)=StdDevx;
FeaturesDt(i,62)=Peak;
FeaturesDt(i,63)=Skewnesss;
FeaturesDt(i,64)=Kurtosiss;
%FeaturesDt(i,70)=Crest_Factor;
%FeaturesDt(i,71)=Clearance_Factor;
FeaturesDt(i,65)=Shape_Factor;
%FeaturesDt(i,73)=Impact_Factor;
%FeaturesDt(i,74)=SMR;

end
% save ('allvars-finaltest');
% load ('allvars-finaltest');
DtPInTest=FeaturesDt(:,:);
PtDInTest=FeaturesPt(:,:);
yDtPt=netDtP(DtPInTest');
yPtDt=netPtD(PtDInTest');

for i=1:length(yDtPt)
    pass=0;
    [M, I] = max(yDtPt(:,i));
    [M2, I3]=max(yDtPt(2:6,i));
    if M2>0.3999
        NNResultt(i,:)= [0 0 0 0 0 0];
        NNResultt(i,I3+1)=1;
        pass=1;
    end
end

```



```

end
if pass==0
if I==1
if M>0.4999
NNResultt(i,:)= [1 0 0 0 0 0];
else
[secondd, I2]=max(yDtPt(2:6,i));
NNResultt(i,:)= [0 0 0 0 0 0];
NNResultt(i,I2+1)=1;
end
else
NNResultt(i,:)= [0 0 0 0 0 0];
NNResultt(i,I)=1;
end
end
end

for i=1:length(yPtDt)
pass=0;
[M, I] = max(yPtDt(:,i));
[M2, I3]=max(yPtDt(2:6,i));
if M2>0.2320
NNResultPt(i,:)= [0 0 0 0 0 0];
NNResultPt(i,I3+1)=1;
pass=1;
end
if pass==0
if I==1
if M>0.4999
NNResultPt(i,:)= [1 0 0 0 0 0];
else
[secondd, I2]=max(yPtDt(2:6,i));
NNResultPt(i,:)= [0 0 0 0 0 0];
NNResultPt(i,I2+1)=1;
end
else
NNResultPt(i,:)= [0 0 0 0 0 0];
NNResultPt(i,I)=1;
end
end
end
end

```

```

% Grafik halde gösterim
%yTotal=yDtPt+yPtDt;
figure
b=bar3(yDtPt)
colorbar
for k = 1:length(yDtPt)
zdata = b(k).ZData;
b(k).CData = zdata;
b(k).FaceColor = 'interp';
end
figure
b=bar3(yPtDt)

```

```

colorbar
for k = 1:length(yPtDt)
    zdata = b(k).ZData;
    b(k).CData = zdata;
    b(k).FaceColor = 'interp';
end

```

6. Öz nitelikleri seçerek hesaplayan alt program (SelectiveFeatureExtract.m)

```

% Extract Features Final program
% Features will be selected as chosen after NCA Analysis
% save selixf; save selixa; save selixfOLD;
function [FeaturesD,FeaturesP]=SelectiveFeatureExtract(DtP,PtD,fileidx)
MaxTresholdFreq=10000; % Special Freq. Filter parameter :Max frequency
level we intrested in , above multiplied by 0
XX=100; %
minFreq=0;
Fs=44100;
    DtPStat2=zeros(65);
    PtDStat2=zeros(65);
load selixf selixS; % NCA ile seçilmiş frekans listesi save selixf selixS;
%load selixa;
    SPL = splMeter;
    [Lt,~,~,~] = SPL(DtP');
    % plot(Lt);
    MaxdBdTP(fileidx)=max(Lt);
    AvgdBdTP(fileidx)=mean(Lt);
    release(SPL);
    SPL = splMeter;
    [Lt,~,~,~] = SPL(PtD');
    % plot(Lt);
    MaxdBpTD(fileidx)=max(Lt);
    AvgdBpTD(fileidx)=mean(Lt);
    release(SPL);
    DeltaSoundMax(fileidx)=abs(MaxdBdTP(fileidx)-MaxdBpTD(fileidx));
    DeltaSoundAvg(fileidx)=abs(AvgdBdTP(fileidx)-AvgdBpTD(fileidx));
release(SPL);
    WPtD=PtD.*hanning(length(PtD))';
    WDtP=DtP.*hanning(length(DtP))';
    WPtDF=fft(WPtD,Fs);% Apply FFT Park to Drive
    WDtPF=fft(WDtP,Fs);% Apply FFT Drive To Park
    %***** Frequency Chooser
    for i=1:length(selixS)
        DtPStat2(fileidx,i)=abs(WDtPF(selixS(i)));
        PtDStat2(fileidx,i)=abs(WPtDF(selixS(i)));%NCA
    end
    limitS=length(selixS);

featsD=autocorrFeatures(DtP,Fs);
featsP=autocorrFeatures(PtD,Fs);
autocorrD(:,fileidx)=featsD;
autocorrP(:,fileidx)=featsP;
[~,~,~,~,~,InstantED,~]=EMDdene(DtP,Fs);
[~,~,~,~,~,InstantEP,~]=EMDdene(PtD,Fs);

Feature2D(fileidx)=mean(max(sum(InstantED))); %Avg of Max. of InstantEntropy

```

```

Feature2P(fileidx)=mean(max(sum(InstantEP)));

NDtP=length(DtP);
NPtD=length(PtD);
endusukD=min(DtP);
if endusukD<0
    NewDtP=DtP-endusukD;
else
    NewDtP=DtP+endusukD;
end
ConvertDtP=db(NewDtP, 'power');
pows=db2pow(ConvertDtP);%*****USE This
powp1p0=pows./0.00002;
Soundlevel=10*log10(powp1p0);
enaz=100;
endeksmin=1;
for gec=1:length(ConvertDtP)
    if ConvertDtP(gec)>-inf
        if enaz>ConvertDtP(gec)
            enaz=ConvertDtP(gec);
            endeksmin=gec;
        end
    end
end
minDtPendeks(fileidx)=endeksmin;
minDtP(fileidx)=enaz; % Time factor 1
pik=0;
minpik=0;
tresholdd=(mean(pows)+((max(pows)-mean(pows))/2));
for sayy=1:length(pows)
    if pows(sayy)>tresholdd
        pik=pik+1; % Time Factor 2
        if pows(sayy)>-inf
            minpik=pows(sayy); % Time Factor 3
        end
    end
end
DtPPeak(fileidx)=minpik; % Time Factor 2
DtPPeakFreq(fileidx)=pik; % Time Factor 3

endusukP=min(PtD);
if endusukD<0
    NewPtD=PtD-endusukP;
else
    NewPtD=PtD+endusukP;
end
ConvertPtD=db(NewPtD, 'power');
pows=db2pow(ConvertPtD);%*****USE This
powp1p0=pows./0.00002;
Soundlevel=10*log10(powp1p0);
enaz=100;
endeksmin=1;

```

```

for gec=1:length(ConvertPtD)
    if ConvertPtD(gec)>-inf
        if enaz>ConvertPtD(gec)
            enaz=ConvertPtD(gec);
            endeksmin=gec;
        end
    else
        end
end
minPtDendeks(fileidx)=endeksmin;
minPtD(fileidx)=enaz; % Time factor 1
pik=0;
minpik=0;
tresholdd=(mean(pows)+((max(pows)-mean(pows))/2));
for say=1:length(pows)
    if pows(say)>tresholdd
        pik=pik+1; % Time Factor 2
        if pows(say)>-inf
            minpik=pows(say); % Time Factor 3
        else
            minpik=-10000;
        end
    end
end
PtDPeak(fileidx)=minpik; % Time Factor 2
PtDPEakFreq(fileidx)=pik; % Time Factor 3

DtPStat2(fileidx,limitS+1)=MaxdBdPtP(fileidx); % NEEDED
DtPStat2(fileidx,limitS+2)=AvgdBdPtP(fileidx); % NEEDED
DtPStat2(fileidx,limitS+3)=DeltaSoundMax(fileidx);
DtPStat2(fileidx,limitS+4)=DeltaSoundAvg(fileidx);
DtPStat2(fileidx,limitS+5)=autocorrD(1,fileidx); %NCA
DtPStat2(fileidx,limitS+6)=autocorrD(2,fileidx); %NCA
DtPStat2(fileidx,limitS+7)=autocorrD(2,fileidx); %NCA
DtPStat2(fileidx,limitS+8)=DtPPeak(fileidx);

PtDStat2(fileidx,limitS+1)=MaxdBPtD(fileidx); %NEEDED
PtDStat2(fileidx,limitS+2)=AvgdBPtD(fileidx); %NEEDED
PtDStat2(fileidx,limitS+3)=DeltaSoundMax(fileidx);
PtDStat2(fileidx,limitS+4)=DeltaSoundAvg(fileidx);
PtDStat2(fileidx,limitS+5)=autocorrP(1,fileidx);%NCA
PtDStat2(fileidx,limitS+6)=autocorrP(2,fileidx);%NCA
PtDStat2(fileidx,limitS+7)=autocorrP(3,fileidx);%NCA
PtDStat2(fileidx,limitS+8)=DtPPeak(fileidx);

FeaturesD(fileidx,:)=DtPStat2(fileidx,:);
FeaturesP(fileidx,:)=PtDStat2(fileidx,:);

End

```

7. Otokorelasyon hesaplayan alt program (autocorrFeatures.m)

```

function feats = autocorrFeatures(x, fs)
feats = zeros(1,5);
minprom = 0.0005;

```

```

mindist_xunits = 0.05;
minpkdist = floor(mindist_xunits/(1/fs));
% Separate peak analysis for 3 different channels
[c, lags] = xcorr(x);
[pks,locs] = findpeaks(c,...
    'minpeakprominence',minprom,...
    'minpeakdistance',minpkdist);
tc = (1/fs)*lags;
tcl = tc(locs);
% Feature 1 - peak height at 0
if(~isempty(tcl)) % else f1 already 0
    feats(1) = pks((end+1)/2);
end
% Features 2 and 3 - position and height of first peak
if(length(tcl) >= 3) % else f2,f3 already 0
    feats(2) = tcl((end+1)/2+1);
    feats(3) = pks((end+1)/2+1);
    feats(4)= tcl((end+1)/2+2);
    feats(5) = pks((end+1)/2+2);
end
end
end

```

EK-4 Temiz Oda Sınıflandırmaları

TEMİZLİK SINIFI		TEMİZLİK SINIFI LİMİTLERİ									
		0.1 µm Birim Hacimler		0.2 µm Birim Hacimler		0.3 µm Birim Hacimler		0.5 µm Birim Hacimler		5 µm Birim Hacimler	
SI	English	m ³	(ft3)	m ³	(ft3)	m ³	(ft3)	m ³	(ft3)	m ³	(ft3)
M1		350	9.91	75.7	2.1	30.9	0.88	10	0.283	-	-
ML5	1	1.240	35	265	7.5	106	3.00	35.3	1	-	-
M2		3.500	99.1	757	21.4	309	8.75	100	2.83	-	-
M2.5	10	12.400	350	2.650	75	1.060	30.00	353	10	-	-
M3		35.000	991	7.570	214	3.090	87.50	1.000	28.3	-	-
M3.5	100	-	-	26.500	750	10.600	300.00	3.530	100	-	-
M4		-	-	75.700	2.140	30.900	875.00	10.000	283	-	-
M4.5	1.000	-	-	-	-	-	-	35.300	1.000	247	7
M5		-	-	-	-	-	-	100.000	2.830	618	17.5
M5.5	10.000	-	-	-	-	-	-	353.000	10.000	2.470	70
M6		-	-	-	-	-	-	1.000.000	28.300	6.180	17.5
M6.5	100.000	-	-	-	-	-	-	3.530.000	100.000	24.700	700
M7		-	-	-	-	-	-	10.000.000	283.000	61.800	1.750

ÖZGEÇMİŞ

Adı Soyadı : İsmail TEPEDAĞ
Doğum Yeri ve Tarihi : Bursa, 1973
Yabancı Dil : İngilizce

Eğitim Durumu
Lise : Bursa Çınar Lisesi
Lisans : Gazi Üniversitesi Endüstri Mühendisliği
Yüksek Lisans :

Çalıştığı Kurum/Kurumlar : Ficosa Türkiye Satınalma Direktörü (2015-Çalışıyor)
Bosal N.V. Sheet Metal Commodity Director (2011-2015)
Hyundai Assan Üretim Kontrol Md.Yrd. (2002-2011)
Mako Elektrik Üretim Mühendisi (1998-2002)
Ak-Pres Bakım ve Boyahane Şefi (1995-1997)

İletişim (e-posta) : ismail.tepedag@ficosa.com

Yayımları :