

**T.C.
AKDENİZ ÜNİVERSİTESİ**



OTOMOBİL MOTOR SESİNDEN MODELİNİN TANINMASI

Efecan KARAMAN

**FEN BİLİMLERİ ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

MAYIS 2018

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



OTOMOBİL MOTOR SESİNDEN MODELİNİN TANINMASI

Efecan KARAMAN

FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

MAYIS 2018

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OTOMOBİL MOTOR SESİNDEN MODELİNİN TANINMASI

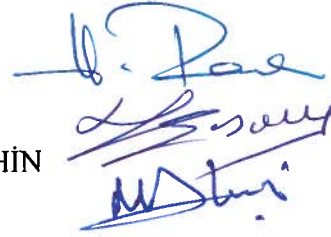
Efecan KARAMAN
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 29.05./2018... tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Prof. Dr. Hikmet RENDE (Danışman)

Doç. Dr. Hakan ERSOY

Dr. Öğr. Üyesi Mehmet Feyzi AKŞAHİN



ÖZET

OTOMOBİL MOTOR SESİNDEN MODELİNİN TANINMASI

Efecan KARAMAN

Yüksek Lisans Tezi, Makine Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Hikmet RENDE

Mayıs 2018, 71 sayfa

Bu tez çalışmasında, ses işleme yöntemleri ve sınıflandırma teknikleri kullanılarak 5 farklı model ve tipteki otomobilin motor seslerinden, bu otomobillerin modellerinin tanınması amaçlanmıştır. Ses kayıtları, yalıtımlı ve kapalı bir ortamda imkanlar dahilinde alınmamıştır. Bu nedenle ses kayıtları, dış ortam seslerinin (insan sesi, kuş sesi, çevre sesleri vb.) en az olacağı düşünülen gece saatlerinde açık bir ortamda alınmıştır. Ses kayıtları alınırken tüm araçlar rölanti halinde çalıştırılmıştır. Otomobiller rölanti halinde çalışırken her otomobilin motorundan ayrı ayrı ortalama 10'ar saniyelik süreler ile 50'şer adet ses verisi toplanmıştır. Toplanan ses verileri bilgisayar ortamına aktarılarak dijitalleştirilmiştir.

Ses verileri incelendikten sonra, her araca ait 50 adet ses verisine welch yöntemi uygulanarak sinyallerin güç spektrum yoğunlukları hesaplanmış ve grafikleri tüm sesler için ayrı ayrı çizdirilmiştir. Güç spektrum grafiklerinden 17 adet farklı frekans bölgesi belirlenmiştir. Bu frekans bölgelerindeki genlik değerleri her araç için öznitelik olarak alınmıştır. Toplamda her araç için 50 adet ses kaydı olup 17 adet öznitelik seçildiğinden 17x50'lik öznitelik matrisi oluşturulmuştur. Çalışmada 5 farklı araç bulunduğu için toplamda 17x250'lik bir öznitelik matrisi elde edilmiştir. Bu öznitelik matrisinden 17x125'lik kısmı sınıflandırma için eğitimde kullanılmıştır geri kalan 17x125'lik kısmı ise eğitilen sınıflandırma yapısında başarı hesaplatmak için kullanılmıştır. Sınıflandırma için Yapay Sinir Ağları, Destek Vektör Makineleri ve k-En Yakın Komşuluk yöntemleri kullanılmıştır. Yapay Sinir Ağları ve k- En Yakın Komşuluk yöntemleri kullanılarak %99.2 başarı oranında, Destek Vektör Makineleri yöntemi kullanılarak %100 başarı oranında sınıflandırma yapılmış ve araç modelleri tanınmıştır.

ANAHTAR KELİMELER: Araç Sınıflandırma, Ses işleme, Sınıflandırma Yöntemleri, Yapay Sinir Ağları

JÜRİ: Prof. Dr. Hikmet RENDE

Doç. Dr. Hakan ERSOY

Dr. Öğr. Üyesi Mehmet Feyzi AKŞAHİN

ABSTRACT

RECOGNITION OF VEHICLE MODELS FROM ENGINE SOUNDS

Efecan KARAMAN

MSc Thesis in Mechanical Engineering

Supervisor: Prof. Dr. Hikmet RENDE

May 2018, 71 pages

In this thesis study, it is aimed to recognize the vehicle models of 5 different model vehicles using their own motor sounds by using sound processing and classification techniques. Sound recordings were not taken in an isolated and enclosed environment. For this reason, the sound recordings were taken in an open environment at night, where the ambient sounds (human voice, bird sound, ambient sounds, etc.) are expected to be minimal. All the vehicles were operated in idle mode while sound recordings were taken. While the vehicles were operating in idle mode, 50 voice sounds were collected every 10 seconds for each car. The collected sound data was digitized by being transferred to the computer.

After examining the sound data, the power spectral densities of the signals were calculated by applying the Welch method to 50 sound data of each interval and the graphs were plotted separately for all sounds. 17 different frequency regions were determined from the power spectrum graphs. The amplitude values in this frequency domain are taken as attributes for each vehicle. When there are 50 voice recordings and 17 feature vectors for each vehicle, the feature matrix is set to 17x50. Since there were 5 different vehicles in the study, a total of 17x250 feature matrices were obtained. The 17x125 part of this matrix was used in training for classification and the remaining 17x125 was used to calculate success in the trained classification. Artificial Neural Networks, Support Vector Machines and k-Nearest Neighbors method were used for classification. 100% success rate was achieved by Support Vector Machine method and 99.2% success rate was achieved by Artificial Neural Networks and k-Nearest Neighbors methods. With these high success rates, the vehicle models were recognized.

KEYWORDS: Vehicle Classification, Sound Processing, Classification Methods, Artificial Neural Networks

COMMITTEE: Prof. Dr. Hikmet RENDE

Assoc. Prof. Dr. Hakan ERSOY

Asst. Prof. Dr. Mehmet Feyzi AKŞAHİN

ÖNSÖZ

Otomobiller günümüz koşullarında en çok ihtiyaç duyulan ulaşım organlarından biridir. Bu çalışma, yıllar geçse de kullanımında bir azalma olmayacağı düşünülen otomobiller üzerinde, otomobillerin motor seslerini kullanarak modellerini sınıflandırmak amacıyla yapılmıştır. Sınıflandırma çalışması sinyal işleme yöntemleri kullanılarak yapılmıştır. Bu çalışmada elde edilebilecek başarı gelecekte araç motorlarının tanınması dışında arıza tespiti vb. gibi alanlarda da veri tabanının artırılması ile uygulanabilir olacağı düşünülmektedir. Ayrıca günümüzde araç tanıma, savunma sistemlerinden akıllı ulaşım sistemlerine kadar birçok alanda da yaygın olarak kullanılmaya başlanmıştır. Çalışmada, ses verilerinin toplanmasından, sinyal işleme yöntemlerinin öğrenilmesi ve ses verilerinin bu yöntemlerle işlenmesine kadar uzun bir süreç geçmiştir.

Bu süreçte, bana bu konuda çalışma olanağı veren, her zaman ve her konuda yardımlarını gördüğüm danışman hocam Sayın Prof. Dr. Hikmet RENDE'ye (Akdeniz Üniversitesi, Mühendislik Fakültesi), çalışmanın her aşamasında yardımını esirgemeyen hocam Sayın Dr. Öğr. Üyesi Mehmet Feyzi AKŞAHİN'e (Başkent Üniversitesi, Mühendislik Fakültesi), her zaman ve her koşulda, tüm kararlarımda yanımda olan, maddi ve manevi desteklerini hiçbir zaman benden esirgemeyen çok değerli ailem; annem Binhan'a, babam İsmail'e, kardeşim Ecem'e, diğer aile büyüklerime ve nişanlım İrem'e sonsuz sevgi ve teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
ÖNSÖZ	iii
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
1.1. Ses Kavramları	3
1.1.1. Sesin temelleri.....	3
1.1.2. Ses dalgaları.....	5
1.1.3. Sesin hızı.....	6
1.1.4. Frekans.....	6
1.1.5. Dalga boyu, periyot, genlik.....	7
1.1.6. Ses basıncı	9
1.1.7. Sesin serbest alanda yayılması.....	10
1.2. Otomobillerde Ses Kaynakları	11
1.3. Ses Tanımda Kullanılan Yöntemler.....	13
1.3.1. Ses tanıma aşamaları	14
2. KAYNAK TARAMASI.....	16
3. MATERYAL VE METOT.....	24
3.1. Materyal	24
3.1.1. Çalışmada kullanılan araçlar.....	24
3.1.2. Çalışmada kullanılan ses kayıt cihazı.....	26
3.1.3. Ses verilerinin alınması	27
3.2. Metot.....	30
3.2.1. Öznitelik vektörlerinin çıkarılması.....	30
3.2.1.1. Spektral analiz.....	30
3.2.1.2. Güç spektral yoğunluğu.....	31
3.2.1.3. Welch yöntemi.....	32
3.2.2. Sınıflandırma yöntemleri	37

3.2.2.1. Yapay sinir aęları (YSA).....	37
3.2.2.2. k-Kat apraz doęrulama algoritması	47
3.2.2.3. Destek vektör makineleri.....	47
3.2.2.4. k-En yakın komşuluk yöntemi.....	49
3.2.3. Otomobil seslerinin sınıflandırılmasında kullanılan yöntemler.....	49
4. BULGULAR VE TARTIŞMA	52
5. SONUÇ.....	67
6. KAYNAKLAR	69
ÖZGEÇMİŞ	



AKADEMİK BEYAN

Yüksek Lisans Tezi Olarak Sunduğum “**Otomobil Motor Sesinden Modelinin Tanınması**” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

Tarih. 29 / 05 / 2018

Efecan KARAMAN

İmzası



SİMGELER VE KISALTMALAR

Simgeler

c	: Ses hızı (m/s)
dB	: Desibel
f	: Frekans (Hz)
Hz	: Hertz
P	: Güç (Watt)
Pa	: Pascal (N/m ²)
T	: Periyot (s)
λ	: Dalga Boyu (m)

Kısaltmalar

DFT	: Ayrık Fourier Dönüşümü (Discrete Fourier Transform)
DTW	: Dinamik Zaman Uydurma (Dynamic Time Warping)
FFNN	: İleri Beslemeli Sinir Ağları (Feed Forward Neural Networks)
HMM	: Gizli Markov Modelleri (Hidden Markov Models)
k-NN	: k-En Yakın Komşuluk Yöntemi (K- Nearest Neighbors)
k-Fold	: k-Kat Çapraz Doğrulama Algoritması (K-Fold Cross Validation)
LPC	: Doğrusal Önkestirim Kodlama (Linear Predictive Coding)
MFCC	: Mel Frekans Kepstrum Katsayıları (Mel Frequency Cepstrum Coefficients)
PSD	: Güç Spektrum Yoğunluğu (Power Spectrum Density)
SPL	: Ses Basınç Düzeyi (Sound Pressure Level)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
YSA	: Yapay Sinir Ağları (Artificial Neural Networks)

ŞEKİLLER DİZİNİ

Şekil 1.1. Ses dalgası (x; zaman y; genlik) (Mut 2005).....	3
Şekil 1.2. Temel ses dalgaları (Nabiyev 2012)	4
Şekil 1.3. Ses dalgası (Özgüven 1986)	7
Şekil 1.4. Bir sinüs dalgasındaki dalga boyu (Aydın 2005).....	8
Şekil 1.5. Genlik (Ses şiddeti)	8
Şekil 1.6. Araçlardaki gürültü kaynakları (Challen ve Baranescu 1999; Demir 2017)	12
Şekil 1.7. Motor gürültü kaynakları (Challen ve Baranescu 1999; Demir 2017)	12
Şekil 1.8. Örüntü tanıma aşamaları (Ölmez ve Dokur 2009).....	15
Şekil 2.1. Ses dalgalarının çerçevelere bölünmesi (Wu vd. 1998).....	16
Şekil 2.2. Sedan otomobil sınıfından kamyon ve motosiklet sınıflandırılması (Wu vd. 1998).....	17
Şekil 2.3. Özellik çıkarma işlemi blok diyagramı (Özgündüz vd. 2010)	19
Şekil 2.4. Asfalt, çakıl, kar ve taşlı yollarda toplanmış ses verileri (Doğan 2017).....	21
Şekil 2.5. Cihaz tanıma sistemi blok diyagramı (Güvensan ve Tayşi 2010)	22
Şekil 3.1. Çalışmada kullanılan 1. araç (Renault Symbol)	24
Şekil 3.2. Çalışmada kullanılan 2. araç (Renault Fluence)	25
Şekil 3.3. Çalışmada kullanılan 3. araç (Peugeot 207)	25
Şekil 3.4. Çalışmada kullanılan 4. araç (Peugeot Partner Van)	26
Şekil 3.5. Çalışmada kullanılan 5. araç (Opel-Zafira)	26
Şekil 3.6. Ses kayıt cihazı	27
Şekil 3.7. Ses ölçümlerinde ses kayıt cihazının yerden yüksekliği (Aydın 2008)	28
Şekil 3.8. Ses kayıt cihazı konumu (örnek olarak ses kayıt işlemi göstermek amacıyla ve görüntünün net olması için gündüz çekilmiştir).....	28

Şekil 3.9. Ses kayıt işlemi (ses kayıt işlemi göstermek amacıyla ve görüntünün net olması için gündüz çekilmiştir)	29
Şekil 3.10. Audacity programında ses verileri üzerinde yapılan işlemler	29
Şekil 3.11. L alfabetik örüntüsü ve öznitelik vektörü (Türkoğlu ve Aslan 1996).....	30
Şekil 3.12. Güç spektral yoğunluğu tahmininde dalgacık analizi yöntemi (Solomon 1991).....	33
Şekil 3.13. Bant geçiren filtre tepkisi (Solomon 1991)	35
Şekil 3.14. Basit nöron modeli (Uslu (2016)'dan değiştirilerek alınmıştır)	38
Şekil 3.15. Hiperbolik tanjant aktivasyon fonksiyonu (Sağiroğlu vd. 2003).....	39
Şekil 3.16. Lineer aktivasyon fonksiyonu (Sağiroğlu vd. 2003).....	40
Şekil 3.17. Sigmoid aktivasyon fonksiyonu (Sağiroğlu vd. 2003).....	40
Şekil 3.18. Bir yapay sinir ağının genel yapısı (Öztemel 2006)	41
Şekil 3.19. İleri beslemeli ağ yapısı (Öztemel 2006)	42
Şekil 3.20. Geri beslemeli ağ yapısı (Öztemel 2006).....	43
Şekil 3.21. İleri beslemeli 2 katmanlı yapay sinir ağı yapısı (FFNN) (Sokouti vd. 2014)	43
Şekil 3.22. Danışmanlı öğrenme yapısı (Ataseven 2013).....	45
Şekil 3.23. Danışmansız öğrenme yapısı (Sağiroğlu vd. 2003).....	45
Şekil 3.24. İki sınıflı bir problem için hiper düzlemler (Kavzaoğlu ve Çölkesen 2010)	48
Şekil 3.25. Optimum hiper düzlem ve destek vektörleri (Kavzaoğlu ve Çölkesen 2010)	48
Şekil 4.1. Renault Symbol (1.araç) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği	52
Şekil 4.2. Renault Fluence (2.araç) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği	52
Şekil 4.3. Peugeot 207 (3.araç) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği	53
Şekil 4.4. Partner Van (4.araç) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği	53

Şekil 4.5. Opel Zafira (5.aracı) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği	54
Şekil 4.6. Renault Symbol (1.aracı) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği.....	54
Şekil 4.7. Renault Fluence (2.aracı) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği.....	54
Şekil 4.8. Peugeot 207 (3.aracı) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği.....	55
Şekil 4.9. Partner Van (4.aracı) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği.....	55
Şekil 4.10. Opel Zafira (5.aracı) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği.....	56
Şekil 4.11. Renault Symbol (1.aracı) aracına ait 1 adet öznelik değeri.....	58
Şekil 4.12. Renault Symbol aracına ait 12 adet ses kaydının 17 farklı öznelik değerleri	58
Şekil 4.13. Yapay sinir ağı eğitim aşaması	59
Şekil 4.14. Yapay sinir ağında kullanılan giriş veri sayısı, gizli katman sayısı ve çıkış verisindeki nöron sayısı	59
Şekil 4.15. Yapay sinir ağı eğitim performans eğrisi	60
Şekil 4.16. MATLAB programındaki sınıflandırma yöntemlerinin bulunduğu araç kutusu	61
Şekil 4.17. Destek vektör makineleri yönteminde eğitim seti	61
Şekil 4.18. Farklı SVM yöntemlerinde eğitim doğruluk oranları	62
Şekil 4.19. Öznelik matrisinin dağılım grafiği.....	62
Şekil 4.20. SVM yönteminde eğitim aşamasını gösteren hata matrisi	63
Şekil 4.21. Farklı kNN yöntemlerinde eğitim doğruluk oranları	64
Şekil 4.22. k-NN yönteminde eğitim aşamasını gösteren hata matrisi.....	64

ÇİZELGELER DİZİNİ

Çizelge 1.1. Sesin çeşitli ortamlarda 21°C'deki yayılma hızları (Demirkale 2007).....	6
Çizelge 1.2. Basınç seviyesi örnekleri (Önen 2016)	9
Çizelge 1.3. Ses tanıma için geliştirilen yöntemler ve tarihleri (Eray 2008).....	13
Çizelge 2.1. SVM ve k-NN yöntemlerinde sınıflandırma başarı oranları (Aykun ve Karşlgil 2009).....	19
Çizelge 2.2. Akustik sinyaller için k-NN ve SVM ile elde edilen başarı oranları (Özgündüz vd. 2010)	20
Çizelge 2.3. Sismik sinyaller için k-NN ve SVM ile elde edilen başarı oranları (Özgündüz vd. 2010)	20
Çizelge 4.1. 17 adet öznitelik ve bu özniteliklerin tespit edildiği frekans değerleri	57

1. GİRİŞ

Günümüz teknolojisinde, otomobillerde oluşan arızalar hala deneyimli ustaların kulak aşinalığından ya da aracın işlevini yerine getirememesi sonucu mecburen servise götürülmesi ile burada bulunan yetkili kişilerin tecrübeleri sayesinde tespit edilebilmektedir. Oysa bu konuda bir çalışma yapılarak otomobil sahipleri, otomobillerinin motorlarında oluşan bir takım sorunları veya arızaları, bir uygulama sayesinde cep telefonlarıyla ya da bir başka cihaz yardımıyla yalnızca ses kayıtlarından tespit etmeleri mümkün olabileceği düşünülmektedir. Böyle bir uygulamanın gerçeğe dönüşmesi için çok fazla sayıda araç örneği ile çalışabilme imkanının olması, bu araçların arıza vermediği zamanlarda ve arıza verdiği zamanlarda alınmış ses kayıtları ayrıca her arıza tipinin araçlarda oluşması ve bu arıza tiplerinin de ses kayıtları kullanılarak tanımlanması dolayısıyla kapsamlı bir veri tabanının oluşturulması gereklidir. Böyle bir veri tabanı ile araçlarda meydana gelecek arızaların ses tanıma yöntemleri kullanılarak sınıflandırılması gerçekleştirilebilir. Bu çalışmanın temelini, ses işleme yöntemleri ve sınıflandırma yöntemlerinin kullanılması ile ses tanıma çalışmalarının yapılması oluşturmaktadır.

Ses tanıma temelde elde edilen ses sinyallerinin analiz edilerek sayısallaştırılma sürecidir. Bu süreç sesin kayıt edilmesi ile başlayıp, sesin işlenmesi, özniteliklerinin çıkarılması ve karşılaştırma yapılarak sesin sınıflandırılması ile sonuçlanmaktadır. Ses tanıma üzerine yapılan çalışmalar 1950’li yıllardan bu yana devam etmektedir. 1950’li yıllarda yapılan çalışmalar çoğunlukla kelime ve rakam tanıma çalışmalarını içermektedir. Ancak yıllar ilerledikçe ses tanıma, haberleşme sektörü yanında savunma ve sağlık sektöründe de önemli çalışmalarda kullanılmaya başlamıştır. Bu nedenle ses tanıma çalışmaları günümüzde yaygın bir kullanım alanına sahip ve güncel konuları içermektedir.

Bu tez çalışmasında, araçların motor sesleri kullanılarak ses tanıma çalışması yapılmıştır. Bilindiği üzere birçok farklı tipte, modelde ve farklı yakıt tipine sahip araçlar bulunmaktadır. Bu araçların motor seslerinden faydalanılarak sınıflandırılması gelecekte bu alanda yapılacak yukarıda da bahsedildiği gibi çalışmalara örnek teşkil edeceği düşünülmektedir. Farklı tip araçlarda meydana gelecek arıza tiplerinin tanınması ile ilgili bir çalışma, ilk olarak bu araçların hangi tipte hangi modelde olduğunun belirlenmesi yani bu araçların tanınması ile başlamaktadır. Bu amaçla, bu tez çalışması otomobillerin modellerinin tanınabilirliğinin tespiti üzerine yapılan bir çalışmadır. Tanıma işlemi ise araçların motor sesleri kullanılarak yapılmıştır. Çünkü araçlardaki motor sesleri, güç aktarma organlarının oluşturduğu sesler, lastikler, egzoz, şanzıman veya süspansiyon sesleri gibi sesler araç tipini tanımlamak için önemli bir ipucu sağlamaktadır. Literatür taraması yapıldığında araçlarda tanıma veya bir başka deyişle sınıflandırma çalışmalarının sıklıkla araç görüntüleri ile görüntü işleme teknikleri, akustik ve sismik sinyal özellikleri, araç içerisindeki elektronik akşamların yarattığı elektromanyetik yayılımlar vb. ses veya sinyallerin kullanılması ile de ses işleme teknikleri kullanılarak yapıldığı görülmüştür. Literatürde araçların motor seslerinin kayıt edilmesi ile sınıflandırılmasına yönelik bir çalışmaya rastlanmamıştır.

Çalışmada, 5 farklı modelde araç kullanılmıştır. Bu araçların özelliklerinden materyal bölümünde bahsedilmektedir. Genel anlamda araçlar içerisinde farklı yakıt tiplerine, farklı kasa tiplerine sahip araçlar ve aynı motora ait fakat farklı modeldeki

araçlar bulunmaktadır. Bu araçların motorlarından alınan ses verileri ile çeşitli ses işleme yöntemleri kullanılarak sınıflandırma çalışması yapılmıştır. Ses verileri yalıtımlı ve kapalı bir ortamda alınmadığı için, trafik sesleri, insan ve kuş sesleri, çevre sesleri gibi dış ortam seslerinin en aza indiği gece saatlerinde alınmıştır. Her araçtan 50'şer adet ses kaydı alınarak ses verileri oluşturulmuştur. İlk olarak ses verileri 10'ar saniyelik sürelerle sabitlenmiştir. Daha sonra çeşitli yöntemlerle ses verilerinden öznitelikler oluşturulmuştur. Bu öznitelikler kullanılarak da farklı sınıflandırma yöntemlerinde araçların modellerin tanınması üzerine çalışılmıştır. Elde edilen sonuçlar incelendiğinde araçların motor sesleri ile sınıflandırılabilceğini söylemek mümkün olmaktadır.


Yapılan tez çalışmasında, otomobil motor sesinden otomobil modelleri tanınarak ileriye dönük arıza tespit uygulamalarına başlangıç aşamasında ışık tutması ve araçların sınıflandırılmasına yönelik çalışmalara katkıda bulunması amaçlanmaktadır.



1.1. Ses Kavramları


1.1.1. Sesin temelleri

Ses, enerjinin katı sıvı veya gaz ortamda transferi esnasında oluşturduğu mekanik titreşimlerdir. Ses sıvı, katı ya da gaz ortamda nesnelere titreşmesiyle oluşturduğu basınç değişimlerine insanların verdiği tepki olarak da tanımlanabilir. Ses oluşması için cismin titreşimi gerekmektedir. Cisimlerin titreşmesi sonucu oluşan dalgalar, ses dalgaları olarak isimlendirilir. Ses, ortamda dalgalar halinde yayılmaktadır. Ses dalgalarını basitçe sinüs dalgaları olarak tanımlayabiliriz. Cisimlerin titreşmesiyle oluşan ses dalgaları, ilerleyebilmek için farklı bir maddenin aracılığına ihtiyaç duymaktadır. Örneğin, sesin yayılmasını suyun içine atılan bir taşın suda oluşturduğu dalgalara benzetmek yanlış olmaz. Suyu atılan taş yüzeye çarptığında o noktada basınç oluşturur. Su sıkıştırılmaz olduğu için taşın suya değdiği noktadaki partiküller yukarı doğru hareketlenir. Taş su içine girdiği zaman ise elastik yapıya sahip olan su yapısı yüzeyini düzleştirilmeye çalışmaktadır. Bu düzleştirme çalışması, su damlacıklarının hareketleri etrafında salınmalara sebep olur. Bu salınma hareketi yakındaki su damlacıklarına iletilir ve dalgacık enerjisi suyun merkez noktasından uzaklaşmaya başlamaktadır. Bu durumda anlatılanlardan yola çıkılarak titreşen bir cisimden, meydana gelen dalgaların katı,sıvı veya gaz ortamda meydana gelen sıkışma ve gevşeme noktaları ile birbirini takip ederek ilerlemesi ses dalgalarını oluşturmaktadır (Demirkale 2007). Ses vakumlu ortamlarda ilerlemez, havada basınç farklılıkları yaratarak ilerler. Bir ses kaynağının ilerleyişi aşağıdaki Şekil 1.1’de verilmiştir.



Şekil 1.1. Ses dalgası (x; zaman y; genlik) (Mut 2005)

Daha öncede bahsedildiği gibi ses bileşik titreşim hareketidir. Periyot ve genlikleri farklı ve başlangıç fazları birbirinden bağımsız birçok titreşimden meydana gelmektedir. Mikrofon ile saf sesli bir veri girişi yapıldığı düşünülürse sinüzoidal bir basınç değişimi oluşur ve dolayısıyla bir sinüs eğrisi oluşur. Ancak gerçek durumda elde edilen eğri bir sinüs eğrisinden daha karmaşıktır. J. Fourier, F frekanslı herhangi bir fonksiyonun, F, 2F, 3F,.. frekanslarındaki sonsuz sayıda sinüzoidal eğrinin üst üste gelmesi ile meydana geldiğini göstermiştir (Nabiyev 2012).



Şekil 1.2. Temel ses dalgaları (Nabiyev 2012)

Sinyal; zaman uzay ya da başka bir bağımsız değişkenle değişiklik gösteren fiziksel nicelik olarak tanımlanabilmektedir. Matematiksel olarak bir sinyal, bir ya da daha fazla bağımsız değişkenin fonksiyonu olarak tanımlanabilmektedir. Örneğin,

$$s_1(t) = 5t \quad (1.1)$$

$$s_2(t) = 20t^2 \quad (1.2)$$

$$s(x, y) = 3x + 2xy + 10y^2 \quad (1.3)$$

fonksiyonları iki sinyali göstermektedir. Denklem 1.1’de verilen ilk sinyal, bağımsız değişken olan zaman değişkeni t ile doğrusal olarak değişmektedir. Denklem 1.2’de verilen diğer sinyal ise bağımsız değişken olan zaman değişkeninin karesi ile orantılıdır. Denklem 1.3’de verilen üçüncü fonksiyonu ele aldığımızda, fonksiyon iki bağımsız x ve y değişkeni olan bir sinyaldir ve bu iki değişken bir düzlemde bulunan iki koordinatı temsil etmektedir (Proakis ve Manolakis 2010). Yukarıda verilmiş olan fonksiyonlar bağımsız değişkenlerle bir bağıntı kurularak tanımlanabilen sinyaller sınıfına girerler. Ancak bazı durumlarda, bağıntı kurulamaz ya da bağıntılar uygulamada kullanılamayacak kadar karmaşık olabilir.

Konuşma sinyali fonksiyonel olarak yukarıdaki fonksiyonlarla tanımlanamaz. Konuşma sinyali genel olarak farklı genlik ve frekanslarda sinüzoidal frekansların toplamı olarak aşağıdaki fonksiyon gibi tanımlanabilmektedir. Fonksiyonda $\{A_i(t)\}$, $\{F_i(t)\}$, $\{\theta_i(t)\}$ sırasıyla sinüzoidlerin genlik, frekans ve faz değişkenleridir.

$$\sum_{i=1}^N A_i(t) \sin[2\pi F_i(t)t + \theta_i(t)] \quad (1.4)$$

Aslında konuşma sinyalinin kısa bir parçasının iletmekte olduğu bilgi veya mesaj içeriğini yorumlamanın bir başka yoluda sinyalin kısa zaman parçacıklarının genlik, frekans ve fazlarını ölçmektir (Proakis ve Manolakis 2010). Konuşma sinyalleri, zamanın yani tek bağımsız değişkenin bir fonksiyonu olarak bilgi taşıyan sinyallere örnek olarak gösterilirken, görüntü sinyali ise iki bağımsız değişkenin fonksiyonudur. Konuşma sinyalleri, insan beyni ve kalbi hakkında bilgi veren elektroensefalogram ve elektrokardiyogram sinyalleri doğal sinyallerin birkaç örneğidir.

Doğal sinyallerin nasıl üretildikleri önemlidir. Örneğin, konuşma sinyali havanın kuvvetli bir şekilde ses telleri arasından itilmesiyle oluşmaktadır. Sinyal oluşturma durumu, bir kuvvete ya da bir dürtüye tepki veren sistemle ilgilidir. Konuşma sinyalinde, sistem ses telleri ve ses boşluğundan oluşmaktadır. Sistemle bir arada bulunan dürtüye ise sinyal kaynağı adı verilmektedir. Konuşma kaynağı, görüntü kaynağı gibi birçok çeşit sinyal kaynağı vardır. Sinyalin üzerinde analizler yapmak amacıyla sinyali bir sistemden geçirdiğimizde ise sinyali işlemiş oluruz. Sinyal işlemede ses sinyalleri, görüntü, elektromanyetik dalgalar vb. kullanılabilir. Ses işleme de, sinyal işleme alanlarından birisidir. Sinyal işleme kategorilendirilecek olursa;

- Analog Sinyal İşleme,
- Ayrık Zamanlı Sinyal İşleme,

olarak, sinyal işlemeyi 2 ayrı kategoride toplamak mümkündür. Analog sinyal işleme, sayısal sinyale dönüştürülmemiş sinyallerin işlenmesinde kullanılmaktadır. Televizyon ve radyolarda bulunan sinyaller analog sinyallere örnek olarak verilebilir. Sayısal sinyal işleme, bilgisayarlar aracılığıyla gerçekleştirilen teknikte sinyal analizi aritmetik operatörler kullanılarak yapılmaktadır. Ayrık zamanlı sinyal işlemede ise analog sinyaller örneklenerek ayrık zamanlı sinyallere çevrilir. İşleme teknolojisi farklı geri beslemeli vb. devrelerde kullanılabilir. Analog ve Ayrık zamanlı sinyaller genellikle lineer değişim göstermezler. Lineer bir başka deyişle doğrusal olmayan sinyal işlemede ise doğrusal olmayan sistemlerden üretilen sinyaller üzerinde işlem yapılmaktadır. Bu yöntemde zaman, frekans gibi parametreler ile analiz yapılabilmektedir fakat karmaşık bir sinyal işleme tekniğidir (Erdemir 2015).

1.1.2. Ses dalgaları

Hava olan ortamdaki maddeler hava molekülleri ile kaplıdır. Titreşen bir obje, etrafındaki kaplı molekülleri dışarı doğru itmektedir. Dışarı doğru itilen moleküller ise etrafındaki diğer molekülleri itmektedir ve bu itme eylemi sürekli olarak devam eder. Bu itme eylemi esnasında moleküller bir araya toplanarak sıkışır. Bu sıkışma, hava basıncını artırır. Diğer taraftan, itilmeye ve sıkışmaya devam eden moleküller titreşim meydana gelen objeden uzaklaştıkça, bu moleküllerin uzaklaştığı yerde düşük basınca sahip bir alan oluşmaktadır. Ses dalgalarının yayılımı titreşen cisimden küresel ve üç boyutlu olarak dışarı doğru olmaktadır. Yayılım esnasında ses dalgaları karşısına çıkan yüzeylere çarpıp yansiyabilir bu duruma ses dalgalarının yansıması denebilir.

Ses dalgaları yüzeylerin içinden geçerek ilerlemeye devam ederse bu duruma da iletim denebilir. Ses dalgalarının elektrik olarak temsili sinyal ya da ses sinyali olarak adlandırılır.

1.1.3. Sesin hızı


Ses dalgalarının yayılması için katı, sıvı ve gaz gibi kütle ve esneklik nitelikleri bulunan ortamlar gerekmektedir. Ortam cinsine göre de ses dalgasının yayılma hızı değişkenlik gösterir. Sesin hızı, hava içinde 21°C sıcaklıkta yaklaşık 344 m/s'dir (Önen 2016). Ses, havada diğer ortamlardan daha yavaş yol almaktadır. Örneğin, sesin suda yayılma hızı yaklaşık 1450 m/s iken çelikte ise yaklaşık olarak 5000 m/s'dir. Aşağıdaki Çizelge 1.1'de sesin çeşitli ortamlarda yayılma hızları görülmektedir.

Çizelge 1.1. Sesin çeşitli ortamlarda 21°C'deki yayılma hızları (Demirkale 2007)

Ortam	Yayılma Hızı (m/s)
Hava	344
Mantar	500
Kurşun	1200
Su	1400
Sert Kauçuk	1400-2400
Beton	3000-3400
Tahta	3300-4300
Dökme Demir	3700
Çelik Alüminyum	5100
Cam	5200

1.1.4. Frekans

Birim zamanda üretilen bir sinyaldeki tekrar etme sayısı frekans olarak ifade edilebilir ve frekansa, sıklık uzayı da denebilir. Frekans birimi Hertz (Hz)'dir. Frekans sesin tizliğini, inceliğini belirler. Birim zamandaki sinyalin tekrar etme sayısı artarsa yani frekans artarsa ses incelik, frekans azalırsa ses kalınlılaşır. Bir başka deyişle frekans, bir partikülün birim zamandaki yer değiştirme ya da salınım sayısına verilen addır (Demirkale 2007).



Şekil 1.3. Ses dalgası (Özgüven 1986)


İnsan kulağının işitebileceği frekans aralığı 20 Hz ile 20000 Hz aralığındadır. 1000 Hz ve üzerindeki frekanslar için kilo Hertz (kHz) kullanılabilir. Bu aralık kişiden kişiye ve yaşa göre de değişiklik gösterebilir. İnsan kulağının işitebileceği aralık 20 Hz-20 kHz olarak kabul edilse de 20 kHz gibi yüksek frekansları az sayıda insan duyabilmektedir. Çocuk ve gençler 17 kHz, yetişkinler ise 15 kHz'in üzerindeki frekansları genellikle duyamazlar ve yaş ilerledikçe de üst frekansları duymak gittikçe zorlaşmaktadır (Önen 2016). İnsan kulağının en duyarlı olduğu frekans aralığı ise 1000-4000 Hz'dir ve anlaşılabilir bir konuşmanın olması için 1000-2500 Hz aralığındaki frekanslar yeterli seviyededir. 20 Hz altındaki frekanslara infrasonik frekanslar, 20 kHz üzerindeki frekanslara ise ultrasonik frekanslar denir (Demirkale 2007).

1.1.5. Dalga boyu, periyot, genlik

Dalga boyu, herhangi bir anda birbirine komşu iki dalga arasındaki mesafeye verilen addır. Bir diğer ifade ile iki sıkışma ya da iki gevşeme bölgesi arasındaki uzaklığa da denebilir (Demirkale 2007). Ses dalgalarında, dalga boyları sesin hızının frekansına bölünmesi ile tayin edilmektedir.

$$\lambda = \frac{c}{f} \quad (1.5)$$

Yukarıdaki Denklem 1.5'de, λ ; Dalga boyu (m), c ; ses hızı (m/s) ve f ; frekans (Hz)'dir.



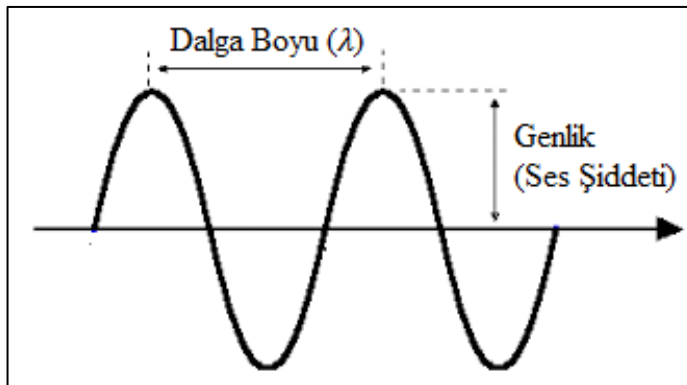
Şekil 1.4. Bir sinüs dalgasındaki dalga boyu (Aydın 2005)

Ses dalgasının bir tam çevrimini tamamlaması için gereken iki sıkışma ya da iki gevşeme bölgesi arasındaki süre ses dalgasının periyodu olarak adlandırılabilir.

$$T = \frac{1}{f} \quad (1.6)$$

Yukarıdaki Denklem 1.6'da, T; periyot (s) ve f; frekans (Hz)'dir.

Sinyal seviyesinin yüksekliği ise genlik olarak adlandırılabilir. Genlik, farklı şekillerde ölçülebilir. Ses titreşiminde, genliğin azlık ya da çokluk ölçütü ses şiddetinin azlık ya da çokluk ölçütüyle doğru orantılıdır. Dolayısıyla genliğin artması ses şiddetinin de artması anlamına gelir.



Şekil 1.5. Genlik (Ses şiddeti)

Bir kaynaktan yayılan ses dalgası, ses kaynağının olmadığı alanlarda büyüyerek yayılır ve yayılma küreseldir. Sesin şiddeti cismin titreşim oranına bağlıdır ve sesin en önemli özelliklerindedir. (Demirkale 2007)

1.1.6. Ses basıncı

Ses atmosferik basıncın anlık meydana gelen değişimlerinden kaynaklanmaktadır. Ses dalgalarının belirli bir alan üzerinde oluşturduğu basınca ses basıncı denir. Ses basıncının birimi Pascal (Pa, N/m²)'dir. İnsan kulağı tek bir noktadan gelen sesin basıncını tayin edemez ancak başka bir ses ile karşılaştırırsa hangi sesin daha yüksek olduğuna karar verebilir. Ses basıncı, ses duyumunun kulakta oluşmasını sağlamaktadır. İnsan kulağının algılama özelliklerine göre yapılan çalışmalarda ses gücünün artması sonucu hissedilen sesdeki artışın logaritmik bir ses şiddeti ile olduğu doğrusal bir duyma olmadığı anlaşılmıştır. Bu nedenle algılanan ses logaritmik olduğu için, ses ve sinyal ölçümlerinde doğrusal form yerine logaritmik form kullanılmaktadır. Ses basınç düzeyi, ses ve sinyal ölçümleri için kullanılan logaritmik birime desibel (dB) denir. Bir başka deyişle desibel elektrik, akustik veya diğer güç değerleri arasındaki oranın logaritmik olarak ifade edilmesi için kullanılan bir birimdir (Önen 2016).

$$dB = 10 \log P/P_{ref} \quad (1.7)$$

Yukarıdaki Denklem 1.7'de, P; güç değeri (Watt), P_{ref}; Referans olarak alınan güç değeri (Watt)'dir. Ses dalgalarının bir alan üzerinde oluşturduğu basınç ise ses basınç seviyesi olarak adlandırılır. Ses basınç seviyesinin birimi, Pascal (Pa) cinsinden ifade edilir. İnsan kulağının duyma eşiği 0.00002 Pa olarak kabul edilmektedir (Önen 2016). Pascal cinsinden basınç seviyeleri ile ilgili olarak aşağıda bulunan Çizelge 1.2. verilmiştir.

Çizelge 1.2. Basınç seviyesi örnekleri (Önen 2016)

Duyma Eşiği	0.00002 Pa
Yaprak hışırtıları	0.0002 Pa
Oda; gece	0.002 Pa
Konuşma	0.02 Pa
Gürültülü bir sokak	0.2 Pa
Gürültülü bir fabrika	2 Pa
Prova stüdyosunda rock müzik	20 Pa
Ağrı eşiği	200 Pa

Pascal cinsinden olan ses basınç seviyesi, dB ses basınç seviyesine dönüştürmek istenirse aşağıdaki Denklem 1.8'deki formül kullanılır. (Önen 2016)

$$dB SPL = 20 \log P/P_{ref} \quad (1.8)$$

Denklem 2.8’de, SPL; ses basınç düzeyi (dB), P; basınç seviyesi (Pascal- Pa), P_{ref} ; referans olarak alınan basınç seviyesini (Pa) ifade etmektedir. Desibel, güç değerine çevirmek istenirse aşağıdaki Denklem 1.9’deki formül kullanılabilir.

$$P = P_{ref} \times 10^{(dB/10)} \quad (1.9)$$

Aşağıda bulunan Çizelge 1.3’de bazı ses kaynaklarına ait ses düzeylerinin desibel olarak karşılıkları verilmiştir.

Çizelge 1.3. Bazı ses kaynaklarının desibel (dB) değerleri (Demirkale 2007)

(dB)	Örnekler	Subjektif Değerlendirme
140	Jet motoruna yakın	Hasar verici
130	Ağrının başlangıcı	
105	Kuvvetli rock müzik	
100	3 m uzaklıkta otomobil klakson sesi	Çok yüksek
90	Şehir cadde gürültüsü	
82	Fabrika gürültüsü	
80	Akustik yalıtım yapılmamış okul, kantin gürültüsü	Yüksek
62	Acık trafikli yol	
62	Tali bir yolun gürültüsü	Orta
50	Büro gürültüsü	
40	Konutta düşük düzeyde çalınan müzik	Düşük
20	Fısıltı	
8	İnsan nefes alış-verişi	Çok düşük
0	İşitmenin başlangıcı	

1.1.7. Sesin serbest alanda yayılması

Ortamın özelliklerine göre sesin yayılması farklılık göstermektedir. Sesin serbest alanda yayılması, sesin yayılmasını etkileyecek yüzeylerle karşılaşmadan ilerlemesidir. Yani sesi yansıtacak engellerin bulunmadığı ve bu sayede sesin düzgün bir biçimde yayıldığı alanlara serbest alan denebilir. Ancak uygulamada sesin yayılmasını engellemeyecek şekilde engellere sahip alanlarda serbest alan olarak kabul edilmektedir. Serbest alanda yayılan ses dalgaları düzgündür. Ses basıncı düzeyi ise serbest alanda ses gücü düzeyinden aşağıdaki formülle hesaplanabilir (Özguven 1986).

$$L_p = L_w + 10 \log (Q/4\pi r^2) \quad (1.10)$$

Denklem 1.10’da, L_p ; kaynaktan r uzaklıktaki ses basıncı düzeyi, L_w ; kaynağın ses gücü düzeyi, Q; yönelme katsayısı ve r; mesafe (m)’dir. Sesin serbest alanda yayılmasına yol açan üç farklı kaynak bulunur. Bu kaynaklar nokta, düzlem ve çizgi kaynak olarak incelenebilir.

Nokta kaynaklar, her yöne eşit dağıtım yapan küresel kaynaklardır. Nokta kaynak olarak tek bir araç incelenirse, araçta gürültüyü oluşturan kaynaklar ise motor, fren, fan sistemi, yol ile fren etkileşimi, egzoz gürültüsü olarak sıralanabilir. Bu

faktörlerin önemi aracın büyüklüğüne, tipine, hızına, bakımına bağlı olarak değişmektedir (Önen 2016).

Çizgi kaynaklar, nokta kaynakların ard arda bir doğrultuda olması ile oluşmaktadır. Çizgi kaynakları denince birçok sayıda ve farklı özelliklere sahip aracın oluşturduğu gürültü baz alınabilir. Bu durumdaki gürültü kaynağına çizgi kaynağı denebilir. Çok sayıdaki nokta kaynağının bir düzlem üzerinde birlikte bulunması ile de düzlem kaynak oluşmaktadır. Ses dalgalarının düzlemsel olarak yayılmasına yol açarlar (Önen 2016).

1.2. Otomobillerde Ses Kaynakları

Hemen hemen hareket eden her araç bir çeşit gürültü üretmektedir. Bu gürültü, çalışan motorun titreşiminden, araç lastiklerinin zeminle teması ve sürtünmesinden, rüzgar etkileri vb. etkilerden meydana gelmektedir. Aynı sınıf olarak adlandırılan aynı türdeki ve benzer koşullarda çalışan araçlar benzer gürültüler oluşturur ve kişiye aidiyeti gösteren imzalar gibi tüm araçların kendine özgü bir gürültü imzası bulunmaktadır. Bu gürültü modeli de bir aracı tespit etmek ve sınıfını tanımak için bir ipucu vermektedir.


Araçlar farklı hızlarda veya farklı ivmelenmelerle farklı yol koşullarında giderken farklı gürültü örnekleri yaymaktadırlar. Bu sesler bir dizi zaman diliminde (çerçeve) örneklenebilir, dijitalleştirilebilir veya gruplanabilirler. Eğer spektrum zamanla değişirse, frekans alanı içinde frekans spektrumlarının dağılımlarının değişimi şeklinde tanımlanabilirler. Araç gürültüleri bir çeşit rastgele (stokastik) sinyaldir (Wu vd. 1998). Stokastik bir sinyal, stokastik özellikleri zamanla değişmeyen ise durağan bir sinyal olarak tanımlanır, aksi takdirde durağan olmayan sinyal olarak adlandırılır.

Araç rölanti halindeyken, gözlem noktasına ses kayıt cihazının araç konumuna yaklaşım uzaklaşırken veya hızlanıp yavaşlarken gürültü oluşturabilir. Ancak ses kaydı uzun bir süreyi kapsadığında sinyal genellikle sabit yani durağan olmayacaktır. Genellikle, ses kayıt cihazının konumu sabit olmaktadır. Araç hareket halinde değilse çalışma koşulları genellikle çok fazla değişmez, ancak araç hareket halindeyse oldukça kısa bir süre ses kayıt edilebilir. Bu nedenle, araç ses sinyalleri genellikle durağan halde iken durağan sinyal olarak uygun bir şekilde işlenmektedir.


Otomobillerde önemli ses kaynaklarını, otomobil motoru ve güç aktarma organları, lastikler, egzoz, şanzıman ve süspansiyon sesleri oluşturmaktadır. Örneğin, motor silindirlerinde meydana gelen yanma olayı, basınç darbesi oluşturur. Bu basınç darbesi ise silindir kapağı ve duvarları aracılığıyla motor gövdesinin titreşimine sebep olmaktadır. Oluşan titreşim, havanın basınç salınımları yapmasına dolayısıyla ses oluşumuna sebep olur. Bu elemanlardan dolayı oluşan gürültüleri yani istenmeyen sesleri tayin etmek ise zordur. Ancak bu sesler sıklıkla oluştuğunda bazı fikirler verebilmektedir.

Ses kaynağı tanıma, cisimlerin çıkardıkları sesler esas alınarak sınıflandırma veya kimliklendirme işlemidir. Ses kaynağı tanımaya yönelik insan sesi tanıma ya da konuşma tanıma alanında yapılan çalışmalar literatürde büyük ilgi ve kabul görmektedir (Aykun ve Karslığıl 2009). Mekanik sesleri incelemek amacıyla yapılan araştırmaların başında ise araç sınıflandırma çalışmaları gelmektedir. Çalışmalarda motorsiklet, araba,

gemi, otobüs, tekerlekli ve paletli araç vb. araçlar sınıflandırılmaya çalışılmakta ve çeşitli oranlarda başarılar elde edilmektedir. Bu çalışmada kullanılan araç sınıfı ise otomobildir ve bu otomobillerin motor sesleri kullanılarak sınıflandırma çalışması yapılmıştır. Aşağıda bulunan Şekil 1.6 ve Şekil 1.7.'de otomobillerdeki gürültü kaynakları gösterilmiştir Şekil 1.6 incelendiğinde, motor gürültülerinin genel anlamda araç gürültü kaynakları içinde %8'lik bir dilime sahip olduğu görülmektedir.



Şekil 1.6. Araçlardaki gürültü kaynakları (Challen ve Baranescu 1999; Demir 2017)



Şekil 1.7. Motor gürültü kaynakları (Challen ve Baranescu 1999; Demir 2017)

1.3. Ses Tanımda Kullanılan Yöntemler

Ses tanınması temelde, mikrofon veya telefon gibi cihazlarla alınmış olan ses sinyallerinin analiz edilmesi yani sayısallaştırılmasıdır. Ses tanıma sistemleri, insan-makine iletişimini kuvvetlendirmektedir. Bu sayede insanlar arasındaki temel iletişim aracı olan sesli iletişim ile insan-bilgisayar arasındaki iletişimin sağlanması ve bu sayede insan hayatının kolaylaştırılması sağlanabilmektedir. Ses tanıma süreci, sesin kayıt edilmesi ile başlayıp, sesin işlenmesi, özniteliklerinin çıkarılıp kaydedilmesi ve karşılaştırma yapılarak sesin sınıflandırılması şeklinde devam etmektedir.

Ses tanıma üzerine yapılan çalışmalar 1950'li yıllardan bu yana devam etmektedir. O yıllarda yapılan çalışmalarda araştırmacılar tek bir konuşmacı için kelime veya rakam tanıma sistemleri üzerine çalışmışlardır (Davis 1952; Olson 1956). Daha sonraki süreçte çalışmalar birden fazla sayıda kelimenin tanınması ve birbirinden ayrılması üzerine yapılmıştır. 1960'lı yıllara gelindiğinde ise ses tanıma üzerine yapılan araştırmalar sesli tanıyıcı donanımları, ve farklı sesli tanımlama metodlarının araştırılması ile devam etmiştir. 1970'li yıllarda, ses tanıma üzerine önemli çalışmalar gerçekleştirilmiştir. Bu çalışmalara bakılacak olursa ayrılmış kelime tanıma çalışması ile ses tanıma içerisinde araştırmacılar örüntü tanıma fikrinin kullanılabilirliği tespit edip geliştirmeye çalışmışlar ve dinamik programlama yöntemlerinin ses tanımda kullanılabileceğini göstermişlerdir.

1980'li yıllara gelindiğinde ses tanımda istatistiksel modelleme yöntemleri çalışmaya başlanmıştır. Bu yıllarda günümüzde kullanımı oldukça yaygın olan ancak fikirleri o zamanlara dayanan yapay sinir ağları teknolojisi gibi ses tanıma üzerine farklı yöntemler ve fikirler oluşmaya başlamıştır. 1990'lı yıllara gelindiğinde yeni yöntemler üzerine çalışmalar devam etmiş, süreç bu şekilde 2000'li yıllara gelerek ses tanıma, konuşmacı tanıma ve doğrulama işlemleri gibi uygulamalar ve yeni yöntemlere dair çalışmalar devam etmiştir (Eray 2008). Aşağıda bulunan Çizelge 1.4.'de ses tanıma yöntemleri ve bu yöntemlerin ortaya çıkış tarihleri verilmiştir.

Çizelge 1.4. Ses tanıma için geliştirilen yöntemler ve tarihleri (Eray 2008)

GELİŞME	TARİH
Doğrusal Önkestirim Kodlama (LPC)	1969-1970
Dinamik Zaman Uydurma (DTW)	1970'ler
Gizli Markov Modeller (HMM)	1975
Mel- Frekans Cepstrum Katsayıları (MFCC)	1980
Yapay Sinir Ağları (YSA) , Dil Modelleri	1980'ler
Destek Vektör Makineleri (SVM)	1995, 1998
Çekirdek Tabanlı Sınıflandırıcılar	1998
Dinamik Bayesian Ağları	1999

1950'li yıllardan bugüne kadar yapılan çalışmalarda amaç her zaman en yüksek doğruluk oranına ulaşmak olmuştur. Ses tanıma sistemleri, sinyal işleme, akustik, model tanıma vb. birçok farklı disiplini içermektedir. Ses tanıma sistemlerinden model tanıma, ses verilerinin prototip olan modellerde gruplandırılması ve örnek model özellikleri esas alınarak bu iki veri seti arasında eşleştirme yapmak için kullanılmaktadır. Bu tez çalışmasında, otomobillerin sınıflandırılması aşamasında yukarıda verilen Çizelge 1.4'deki ses sınıflandırma yöntemlerinden Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (SVM) yöntemleri kullanılmıştır. Bu nedenle bu iki sınıflandırma yöntemine ait detaylı bilgi alt bölümlerde verilmiştir.

1.3.1. Ses tanıma aşamaları

Ses tanıma aşamaları ilk olarak sesin sentezi ve analizi ile başlamaktadır. Ses analizi kısmında ses kayıt cihazı ile elde edilmiş olan ses sinyallerinin sayısallaştırılması için çalışılmaktadır. Bu aşamada, sesin parametrik bir ifadeye dönüştürülmesi amaçlanır ve ses için ayırıcı özellikler tespit edilir. Bu özellikler daha sonra ses tanıma işleminde giriş verisi olarak kullanılmaktadır. Ses analizinde, ses verilerinin sayısallaştırılması, öznelik vektörlerinin elde edilmesi, spektral analiz, sesin fourier dönüşümü gibi işlemler yapılmaktadır.

Ses tanınması amacıyla ilk olarak ses verisi kayıt edilmektedir. Bu şekilde herhangi bir işlemde geçirilmemiş bir ses verisi elde edilmiş olur. Daha sonraki aşamada yukarıda da bahsedildiği gibi ses sinyali sayısallaştırılmaktadır. Sayısallaşan ses sinyali üzerinde sinyal işleme tekniklerini uygulayarak sesin ayırt edici özellikleri çıkarılmaktadır. Daha sonraki aşamada elde ettiğimiz ayırt edici özellikler bazı teknikler ile modellenmektedir. Modelleme aşamasından sonra elimizde bir ses modeli oluşmuştur. Elde edilen ses modeli veritabanında bulunan diğer verilerle karşılaştırılmaktadır. Ses modeli, veritabanında bulunan verilerle en iyi oranda eşleştirilmeye çalışılır. Bütün bu süreç ses tanıma işlemini gerçekleştirmektedir.

Ses girdisi bir kayıt cihazı ile yapıldıktan sonra, sesin sayısallaştırılması aşamasında analog ses sinyali sayısal ses sinyaline dönüştürülmektedir. Bu dönüşümün sebebi, sayısal tekniklerin daha kolay bir şekilde ve çok daha hızlı olarak gerçekleştirilebilmesidir. Analog ses sinyali sayısal sinyale dönüştürülürken örnekleme, nicelendirme ve kodlama gibi aşamalardan geçmektedir. Örnekleme aşaması, sayısal sınıyalden belirlenen anda genlik değerlerinin alınması olarak tanımlanabilir. Nicelendirme kısmında ise örneklenmiş olan analog ses sinyali belirli aralıklara bölünmektedir. Kodlama aşaması ise, nicelendirilen analog sinyalinin herhangi bir sayı sisteminde gösterilmesidir (Nabiyev 2012).

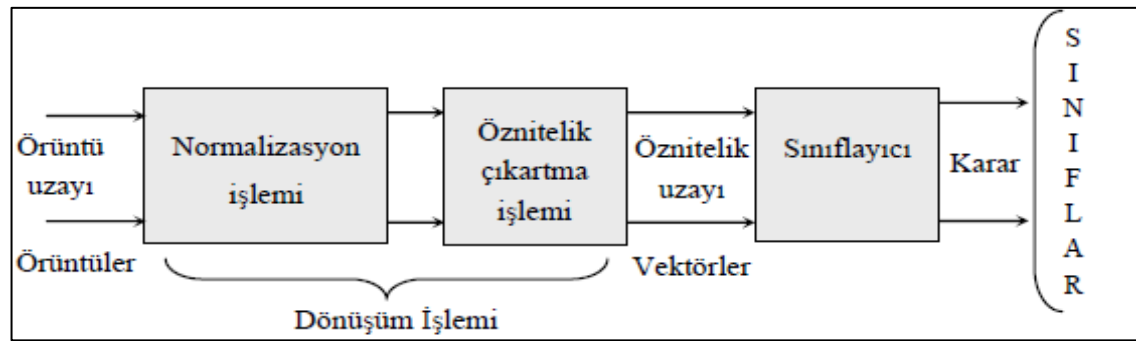
Ses tanıma, aralarında ortak özellikler bulunan ve ilişki kurulabilen işaret veya nesnelerin bazı belirgin özelliklerini, makineler aracılığıyla tanımlama veya sınıflandırma işlemidir. Bu nedenle ses tanımanın en önemli amaçları, bilinmeyen ses sınıflarını nitelendirerek bilinen bir sınıfa ait sesi tanımlamaktır. Ses tanımadaki sistemin eğitilmesi ve sesin tanınması üzerinde durulmaktadır. Eğitim aşamasında sistemin özellikleri, giriş ses verileri incelenerek ortaya çıkarılmaktadır. Tanıma aşamasında ise veri tabanındaki bilgilerle ses verilerinin özellikleri karşılaştırılmaktadır. Giriş ses verisinde birçok ilgili ve ilgisiz bilgi bulunmaktadır. Bu nedenle ses tanıma işleminde ilgili bilgiler seçilerek ilgisizlerden ayrılmalıdır (Nabiyev 2012).

Ses tanıma tekniklerinin uygulamaları birçok alana açıktır. Örneğin; mikroskoplardan elde edilen tıbbi görüntülerin, magnetik rezonans görüntülerinin, X-ışını görüntülerinin ve fotoğrafların otomatik olarak analiz edilmesi, İnsan konuşmasının bilgisayarlar tarafından tanınması, petrol ve mineral araştırmaları ve deprem tespitinde sinyallerin sınıflandırılması, parmak izi veya el şekli ve büyüklüğünden, ses karakteristiğinden veya el yazısından kimlik tespiti gibi uygulamalarda kullanılmaktadır. Ayrıca insan yaşantısında da örüntü tanıma uygulamalarına sıkça rastlanmaktadır. Örneğin, havada meydana gelen değişimlerin algılanması, hayvan türlerinin ayrıştırılması gibi birçok olayda örüntü tanıma kullanılmaktadır. İnsanlarda örüntülerin tanınması geçmişte elde ettikleri tecrübelerden elde edilen bilgilerle doğru orantılıdır (Altınörs vd. 2008).

Ses tanıma temel olarak üç aşamadan oluşmaktadır. Bu aşamalar; Algılayıcılar, öznitelik çıkarma ve sınıflandırmadır. Algılayıcılar, herhangi bir anda mümkün olan veya olabilecek doğal durumlardan biri olan fiziksel işlemleri ölçer. Sesin algılandığı, işaret veya görüntünün filtre edildiği ve işlendiği, bileşenlerine ayrıldığı veya modellendiği kısımdır (Nabiyev 2012).

Öznitelik çıkarma aşaması, ses, işaret veya görüntülerin veri boyutunun indirgenerek, bu verilerden belirleyici özelliklerin tespit edilerek ayrıldığı kısımdır. Bu aşama sistemin başarılı olmasında etkin bir rol oynar.

Sınıflandırma aşaması ise, elde edilen öznitelik kümesinin indirgenildiği ve çeşitli yöntemler kullanılarak formülize edilmesi ile tanımlama işleminin yapılmasıdır. Sınıflandırıcının rolü, sesi, elde edilen özniteliklerden de faydalanılarak özelliklerine göre kategorize etmek ve uygun sınıflara ayırmaktır. Bu çalışmanın ana konusu olan ses tanıma ise örüntü tanıma içerisinde bulunan bir alandır. Çalışmada kullanılan algılayıcı yani ses kayıt cihazının özellikleri, ses kayıt işlemi ve kayıt edilen seslerin özellikleri, öznitelik çıkarma ve sınıflandırma yöntemleri tezin materyal ve metot bölümünde detaylı olarak anlatılmıştır.




Şekil 1.8. Örüntü tanıma aşamaları (Ölmez ve Dokur 2009)

2. KAYNAK TARAMASI

Bir aracın (motor, gürültü vb.) sesi, araç tipini tanımlamak için önemli bir ipucu sağlamaktadır. Bu bölümde araçlardan veya farklı nesnelere elde edilen çeşitli sinyallerin, farklı ses işleme teknikleri ile tanınması ve sınıflandırılmasına yönelik yapılmış çalışmalar incelenmiştir.


Wu vd. (1998), gürültü kalıplarını karakterize ederek yeni algılanan bir sesin bilinen tipte araçtan olup olmadığını ve eğer bilinen bir araç ise tipini sınıflandırmaya yönelik bir çalışma yapmışlardır. Kayıt edilen ses dalgası, 22.025 kHz'lik örnekleme oranında dijitalleştirilmiştir. İlk olarak veriler, 0 ortalama genliğe normalize edilmiştir. Daha sonra veriler 4096 örneğin bulunduğu N çerçeve içine, her çerçeve, $(\bar{X}_n; n=1,2,\dots,N)$ olacak şekilde birbirine komşu 512 örneğe ayrılarak Şekil 2.1'de görüldüğü gibi bloke edilmiştir. \bar{X}_n çerçevesinde bulunan $x_{ni}; i = 0,1,\dots,4095$ örnek için Hamming pencerelemesi yapılmıştır.



Şekil 2.1. Ses dalgalarının çerçevelere bölünmesi (Wu vd. 1998)

Ön işleme uygulanmış tüm çerçevelere hızlı fourier transform algoritması uygulanarak 4096 fourier katsayısı elde etmişlerdir. Ses örüntüsünün tanınmasında fourier faz bilgisi çok önemli olmadığını düşünerek analizde güç spektrumu dikkate alınmıştır. 5.4 Hz ile 11.0125 kHz frekans aralığında eşit aralıklara yerleştirilmiş 2048 adet güç spektrum bileşeni elde etmişlerdir. Ancak araçların %80'inde güç spektrumu 2000 Hz altındaki frekanslara yoğunlaşmış, %90'ında ise 4000 Hz altındaki frekanslara yoğunlaşmış olduğundan 2048 bileşenden ilk 1200 bileşeni dikkate alarak hesaplama süresi ve hafıza gerekliliğini azaltmışlardır. Çalışmada tanıma yapmak için hedeflenen akış şeması, birbirinden en iyi ayrışım yapılabilecek test gruplarından en iyi bilgiyi almak üzerine kurulmuştur. Bu yaklaşımda gürültü frekans dağılımı değişimleri, küçük örnekleme setlerine dönüştürülür. Çalışmada, aynı tipteki araçlardan aynı koşullar altında alınmış olan spektrumlar $\phi_1, \phi_2, \dots, \phi_N$ şeklinde eğitim setlerine uyarlanmıştır. Mikrofon önünden geçen her araç için 4-5 sn'lik kesintisiz sinyal alınabilmektedir. Çalışmada her spektrum analizi için yaklaşık 0.2 sn'lik bir çerçeve kullanılmış ve sınıflandırma için birkaç düzine numuneye gerek duyulmuştur. Eğitim grubunun oluşturulması aşamasında normal koşullar altında kaydedilen örnekler, eğitim grubunun

temel öğrenme örnekleridir. Bu çalışmada aynı yoldan aynı hızda ve aynı hava koşullarında geçen sedan tipi araçlar temel öğrenme örnekleri olarak seçilmiştir. Eğitim setine yeni veriler eklendiğinde, benzer spektrum şeklinde sahip iki kümenin birleştirilmesi önemlidir. Aksi takdirde yeni veriler, orjinal verilerin ve yeni verilerin özelliklerini birbirine karıştırabilir. Çalışmada, kayıt mikrofonu geçen araçların gürültüsünü kaydetmek için sabit bir yere yerleştirilmiştir. Kayıt edilen verilerde sedan araçların geçiş hızları sıklıkla 20-30 mph olduğu görülmüştür. Bu nedenle ses sınıflarını oluştururken en tipik örnekler baz alınmıştır. Özvektörler ve ortalama spektrum vektörü ile karakterize bir model oluşturulmuştur. Model oluşturulduktan sonra, farklı tiplerde araçlar test edilmiştir. Şekil 2.2’de kamyon ve motosiklet gürültülerinin sınıflandırma sonuçları gösterilmiştir.



Şekil 2.2. Sedan otomobil sınıfından kamyon ve motosiklet sınıflandırılması (Wu vd. 1998)

Şekil 2.2’de bulunan figürlerden +, eğitim setindeki araçların kalıntı vektörlerini, x figürü, rastgele seçilmiş araçların kalıntı vektörlerini ve o figürü ise, diğer sınıftaki (kamyon ve motosiklet) araçları ifade etmektedir. Wu vd. yaptıkları çalışma ile araba, kamyon ve motosiklet seslerini tanımaya yönelik temel bileşen analizi yöntemi ile güç spektrumundan türetilen özellikleri kullanarak küçük veri tabanı ile farklı sınıflardaki araçları kümeleyebilmişlerdir. Ayrıca çalışmalarında daha fazla veri ile, eğitim ve test seti arasındaki dağıtım farkının azalacağını ve böylece sınıflandırmanın daha doğru olacağını ve kayıt koşullarının dijital mikrofon veya yüksek performanslı kayıt cihazlarının kullanımı gibi daha hassas ekipmanlarla sağlanması durumunda sonuçların daha doğru olacağını düşünmüşlerdir.

Aykun ve Karşılıgil (2009), deniz taşıtlarının çalışma seslerini değerlendirerek sınıflandırılması üzerine bir çalışma yapmışlardır. Deniz taşıtlarının motor, pervane gibi kısımlarının çalışma sırasında ortama yaydıkları sesleri inceleyerek karakteristiklerini belirlemişlerdir. Daha sonra bu karakteristikleri değerlendirerek gemi modelini tanıma üzerine çalışmışlardır. Karakteristik özelliklerin elde edilmesinde Mel Frekans Kepstral Katsayıları yöntemini kullanarak elde edilen özellikleri k-ortalama yöntemi ile sınıflandırmaya hazır hale getirmişlerdir. Sınıflandırma aşamasında ise k-En Yakın Komşuluk yöntemi kullanılmıştır. Çalışmalarında seyir halindeki gemilerden hidrofonlar aracılığıyla alınmış ses örneklerini kullanmışlardır. Sınıflandırma aşamasında iki aşamalı hiyerarşik bir yapı kullanılmıştır. Benzer özelliklerdeki gemiler bir ana sınıf altında değerlendirilmiş, daha sonra her bir sınıfta bulunan gemilerin modelini belirlemek amacıyla ikinci bir alt sınıflandırma yapmışlardır. 42 farklı örnek gemi sesi kullanılmıştır.

Yayınlanan bu çalışmada ilk olarak ön vurgulama yapılarak yüksek frekanstaki sesler güçlendirilmiş ve oluşan parazit etkileri engellenmiştir. Daha sonra kulağın sesleri algılaması ve ayırt etmesini taklit etmesi amacıyla Mel Frekans Kepstrum Katsayıları işlemi yapılmıştır. Çalışmada yaklaşık 30 sn uzunlukta ses örnekleri kullanılmıştır. Analog ses sinyallerinin örnekleme hızı 16000 Hz ile yapıldığı için her bir ses dosyası için yaklaşık 48000 örnek elde edilmiş ve çerçeve adım değeri 125 olarak hesaplanmıştır. Çerçeve adım değerini hesaplarken örnekleme hızının çerçeve hızına oranı alınmıştır. Çerçeve genişliği 256 olarak seçilmiş ve çerçeve sayısı 3838 olarak hesaplanmıştır. Çerçeveler elde edildikten sonra mel ölçekli filtre bankasını elde etmek amacıyla 0.1 kHz aralığında 13 lineer filtre ve 1.6- 4 kHz aralığında 27 logaritmik filtre ile toplamda 40 filtre elde edilmiştir. MFCC işlemi için kepsstral katsayısı adeti 13 olarak seçilmiş ve MFCC işlemi sonucunda giriş sinyali uzunluğuna bağlı olarak 3800-3900 aralığında değişen her biri 13 karakteristik içeren öznelik vektörleri elde etmişlerdir. Öznelik çıkarımının ardından elde edilen 3800x39 boyutundaki özellik matrisleri, k-ortalama yöntemi ile 128x39 boyutlu sınıflandırmaya hazır öznelik matrisleri haline getirilmiştir.


Bilinmeyen bir gemi sesi kaydının eğitim setindeki ses kayıtlarına benzerliğini değerlendirerek sınıflandırma işlemini gerçekleştirmişlerdir. Ses kaydının eğitim setindeki örneklerden hangisine daha çok benzediğine karar vermesi için Destek Vektör Makineleri (SVM) ve k-En Yakın Komşuluk (k-NN) yöntemlerini kullanarak sınıflandırma başarı oranlarını değerlendirmişlerdir.

Çizelge 2.1. SVM ve k-NN yöntemlerinde sınıflandırma başarı oranları (Aykun ve Karşılıgil 2009)

Yöntem	Özellik Sayısı	Ana Sınıf Tanıma Başarısı	Alt Sınıf Tanıma Başarısı
SVM	128	%90.47	%47.61
k-NN	128	%85.71	%69.04

Çizelge 2.1’de görüldüğü gibi taşıtın ait olduğu ana sınıfın bulunmasında SVM yönteminin k-NN yöntemine göre daha iyi performans sağladığı, taşıtın ne olduğunun bulunmasında yani alt sınıf tanınmasında ise k-NN yönteminin daha başarılı olduğunu tespit etmişlerdir. Bu nedenle sınıflandırmada k-NN yöntemini kullanmışlardır. Ses veritabanının artırılması ve ses örneklerinin daha kaliteli kayıt edilmesinin sağlanması ile başarı oranının artabileceğini düşünmüşlerdir.

Özgündüz vd. (2010), akustik ve sismik sinyal özelliklerine göre iki farklı aracın sınıflandırılması üzerine çalışmışlardır. Sinyallere ait karakteristik özellikleri elde etmek amacıyla Mel Frekans Kepstrum Katsayıları yöntemini kullanmışlardır. Elde ettikleri karakteristik özellikleri vektör kuantalama yöntemini ile özellik azaltımı yaparak sınıflandırma aşamasına geçmişlerdir. Sınıflandırma aşamasında, k-NN ve SVM yöntemlerini kullanmışlar ve yöntemlerin başarı oranlarını değerlendirmişlerdir. Çalışmada, iki farklı aracın akustik ve sismik sensörlerini kullanarak 4960 Hz örnekleme frekansında, 9 test sürüşü esnasında 2’şer dakikalık kayıtlar alınmıştır.



Şekil 2.3. Özellik çıkarma işlemi blok diyagramı (Özgündüz vd. 2010)

Özellik çıkarma işlemi yapıldıktan sonra araçlara ait verileri içeren sinyal parçalarını 512 örneklilik çerçevelere bölmüşlerdir. Her çerçeve için ayrı ayrı hamming penceresi yöntemi ile pencereleme işlemi yapılmış ve 10.32 ms’lik her bir blok için 13 adet katsayıyı Mel Frekans Kepstrum Katsayıları yöntemi ile belirlemişlerdir. Bu işlem sonunda her 120 saniyelik araç sesi örneği için 1162*13 boyutlu bir özellik vektörü elde edilmiştir. Vektör kuantalama yöntemi ile örnekler 13 özellikli 128 kümeye indirgenmiştir. Özellik vektörünün azaltılması ile tanıma işlemi süresinin kısalması ve sınıflandırma başarı oranının artması sağlanmıştır. Sınıflandırma aşamasında ise Destek Vektör Makineleri ve k-En Yakın Komşuluk yöntemleri uygulanarak başarı

oranları karşılaştırılmıştır. Aşağıdaki Çizelge 2.2 ve 2.3'de bu yöntemler arasındaki başarı oranları verilmiştir.

Çizelge 2.2. Akustik sinyaller için k-NN ve SVM ile elde edilen başarı oranları (Özgündüz vd. 2010)

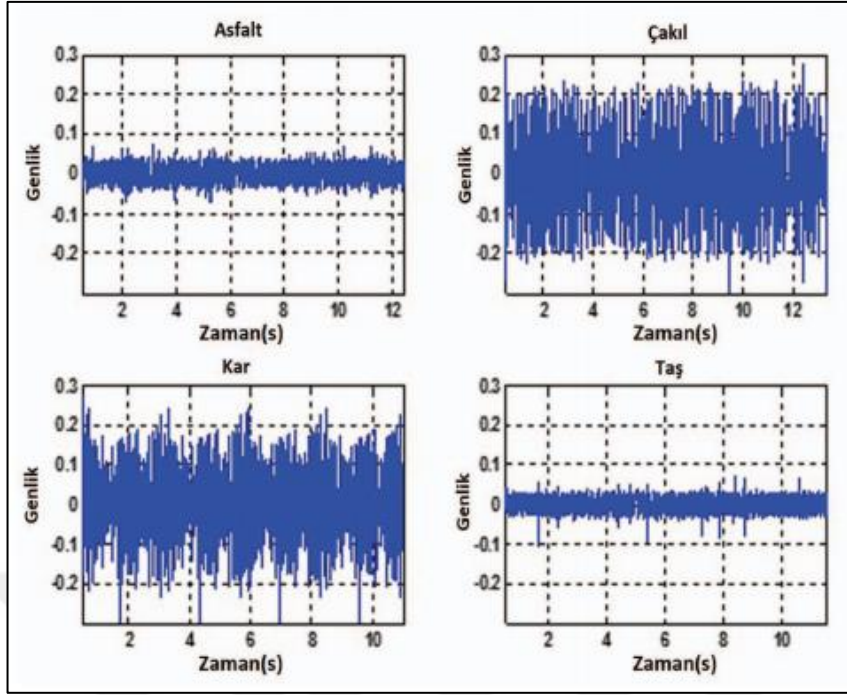
	k-NN k=1	k-NN k=3	k-NN k=5	SVM
1.Araç	0,83	0,79	0,75	0,88
2.Araç	0,79	0,79	0,88	0,75
Ortalama	0,81	0,79	0,82	0,82

Çizelge 2.3. Sismik sinyaller için k-NN ve SVM ile elde edilen başarı oranları (Özgündüz vd. 2010)

	k-NN k=1	k-NN k=3	k-NN k=5	SVM
1.Araç	0,92	0,92	0,92	0,67
2.Araç	0,79	0,79	0,71	0,54
Ortalama	0,86	0,86	0,82	0,60

Akustik ve sismik sinyallerin sınıflandırılması incelendiğinde akustik sinyaller için k=5 katsayısında, k-NN yöntemi ve SVM yöntemi en yüksek ortalama sonuçları elde etmiştir. Başarı oranı bu iki yöntemde de fazla iken tanıma karmaşıklığı SVM yöntemlerinde k-NN yöntemlerine göre daha düşük olduğu için SVM yöntemi tercih edilmiştir. Sismik sinyallerin başarı oranları incelendiğinde k=1 ve k=3 için uygulanan k-NN yöntemi en başarılı sonucu vermiştir ve işlem sayısını azaltmak amacıyla k=1 için k-NN yöntemini seçmişlerdir. Başarı oranları incelendiğinde %82 ve %86 oranları görülmektedir ve bu oranlar ile çalışmada kullanılan sensörlerin araç tanımda kullanılabileceği sonucuna varılmıştır.

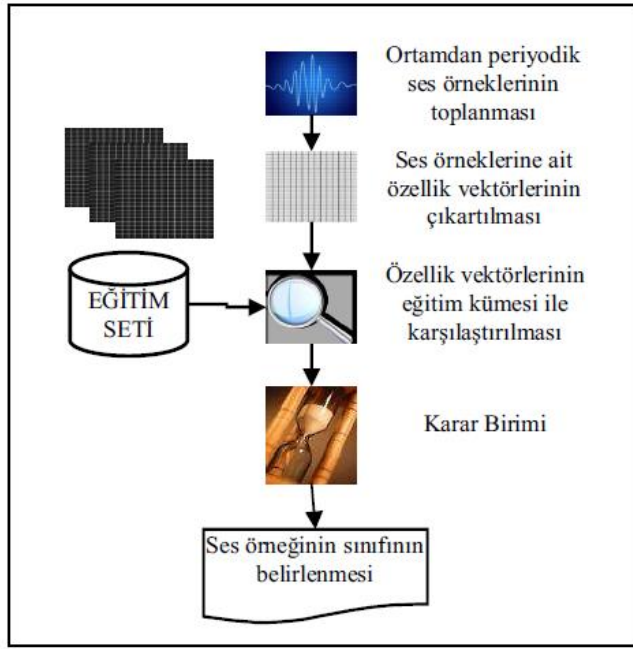
Doğan (2017), asfalt, çakıl, karlı ve taşlı yol olmak üzere dört adet farklı yol koşulunda yol ve lastik arasında elde edilen ses verilerinin işlenmesi ve sınıflandırılması üzerine bir çalışma yapmıştır. 44100 Hz örnekleme frekansında 20 km/h sabit hızda ilerleyen bir elektrikli araçtan asfalt, çakıl, karlı ve taşlı olmak üzere dört farklı yol koşulunda ses verileri toplanmıştır.



Şekil 2.4. Asfalt, çakıl, kar ve taşlı yollarda toplanmış ses verileri (Doğan 2017)

Dört farklı yol koşulunda toplanan ses verilerinden, 0.1 saniye uzunluğunda rastgele 30 örnek alınmıştır. Daha sonra öznelik çıkarma işleminde, her yol koşulu için 30×7 'lik toplamda ise 120×7 'lik öznelik vektörü oluşturulmuştur. Öznelik vektörlerinin veri merkezlerinin uzaklıkları Kullback- Leibler mesafesi yöntemi kullanılarak bulunmuştur. Kullback- Leibler mesafesinin kullanım amacı yol gruplarının birbirlerinden ayrılabilirliğine bakmaktır. Bu çalışmada taşlı yol verisi Kullback-Leibler mesafesi için merkez olarak kabul edilmiştir. Öznelik vektörünü belirlerken minimum varyans ve maksimum uzaklık ilkesini dikkate alınmıştır. Çalışmada, veri merkezlerini karşılaştırarak taşlı, çakıl ve asfalt yolların sınıflandırması yapılmıştır. Yol koşulları arasında sınıflandırma işlemi, Destek Vektör Makineleri yöntemi ile keppstrumlardan oluşan öznelik vektörünü kullanarak yapılmış ve %97.5 başarı oranına ulaşmıştır.

Güvensan ve Tayşi (2010), ev ortamındaki sesleri değerlendirerek çalışan ev aletlerinin tanınması üzerine bir çalışma yapmışlardır. Ortamdan toplanan sesin hangi ev aleti veya ev aletlerine ait olduğunu ve bu ev aletlerinin çalışma modlarını belirlemek amacıyla sınıflandırma yapmışlardır. Çalışma, eğitim ve test olmak üzere iki aşamadan oluşmuştur. Eğitim ve test işlemleri için gerekli veriyi, bir ev içerisinde toplanan ses örneklerinden oluşturulmuş ev cihazları ses veritabanından elde etmişlerdir. Şekil 2.5'de oluşturulan sınıflandırma sistemi görülmektedir.



Şekil 2.5. Cihaz tanıma sistemi blok diyagramı (Güvensan ve Tayşi 2010)

Ses örnekleri, farklı gün ve saatlerde 30 saniye uzunluğunda ölçümler alınarak toplanmasına rağmen telsiz algılayıcı düğümlerin sınırlı veri depolama kapasiteleri nedeniyle program aracılığıyla 1 saniye uzunluğunda kliplere bölünerek veri tabanı oluşturulmuştur. Ses örnekleri Audacity programı kullanılarak toplanmıştır. Ev cihazları ses veritabanında; buzdolabı, mikser, aspiratör, bulaşık makinesi, çamaşır makinesi, saç kurutma makinesi ve havalandırma cihazlarının farklı çalışma modlarına ait ses örnekleri yer almaktadır. Yapılan çalışmada, ortamda ev aletlerinin sesini bastırarak belirgin seviyede bir gürültünün olmadığı varsayılmıştır. Ev aletlerinin ürettikleri seslere bakıldığında baskın frekansların 0-1 kHz aralığında bulunduğu gözlenmiştir. Çalışmada kullanılan algılayıcı düğümlerin kısıtlı veri depolama kapasitelerini de göz önüne alarak örnekleme frekansı 8 kHz olarak seçilmiştir. Mel frekans kepsitrim katsayılarının özelliklerinin hesaplanması için 0.1 kHz aralığını kapsayan 13 adet lineer filtre kullanılmıştır. Sistemde sınıflandırma için SVM ve k-NN yöntemleri kullanılmıştır.

Çalışmada mutfakta yer alan dört adet farklı cihaz ve bu cihazlara ait farklı çalışma modları kullanılmıştır. Bulaşık makinesi, buzdolabı, aspiratör, mikser incelenen cihazlardır. Ayrıca sistemde çekmece/dolap kapanması, yürüme, konuşma, bulaşık yıkama vb. mutfakta gerçekleşebilecek rutin aktivitelerin seslerini içeren diğer isimli veri sınıfı da yer almıştır. Yalnızca tek bir cihazın çalıştığı varsayılan testlerde, diğer ses sınıfı ile birlikte 7 adet farklı sınıf yer almaktadır. Birden fazla cihazın çalıştığı varsayılan senaryoda ise toplam 19 adet sınıf yer almıştır. Her sınıf için 60 adet klip kullanılmıştır. Destek vektör makineleri algoritması kullanılarak %98 oranında ayırt etme başarısı sağlanmıştır. Yapılan çalışma sonucunda aynı anda çalışan, insan kulağının ayırt edemediği birden fazla cihazı, ürettikleri ses bilgileri kullanılarak ayırt etmenin mümkün olduğu görülmüştür.

Literatürdeki çalışmalar incelenmiş olup, literatürden farklı olarak bu tez çalışmasında ses tanıma işlemi otomobillerin motor sesleri kullanılarak yapılmıştır. Literatürde sınıflandırma çalışmalarında kullanılan yöntemlerin çoğunlukla SVM ve k-NN yöntemleri olduğu görülmüştür. Literatürde kullanılan bu yöntemlerden de faydalanılarak çalışmaya ayrıca yapay sinir ağları yöntemi de eklenmiştir. YSA, SVM ve k-NN yöntemlerinin sınıflandırmadaki başarı oranları ayrı ayrı incelenmiştir. Çalışma detayı, materyal ve metot bölümünde anlatılmıştır.



3. MATERYAL VE METOT

Tez çalışmasında, tanımlamada kullanılacak araçlar üzerinden ses kayıtları alınmıştır. Kullanılan araç çeşidi otomobildir. Otomobil rölantide çalıştığından elde edilen sesler stokastik yani bir çeşit durağan sinyal türüdür. Bu şekilde otomobilden makul bir şekilde sinyal alınabilir (Wu vd. 1998). Ancak otomobil hareketi esnasında oldukça değişken bir ses sinyali alınır. Bu nedenle otomobiller rölanti halinde çalışırken ses verileri toplanmıştır. Farklı modeldeki 5 adet otomobil motorundan belli aralıklarla ses kayıt cihazı yardımıyla ses verileri toplanmıştır. Ses verileri dijitalleştirilmiştir. Daha sonra akustik sinyaller bilgisayar ortamına atılmış ve araçları karakterize edecek parametreler çeşitli yöntemler kullanılarak belirlenmiştir. Sinyallerden elde edilmiş olan ayırt edici parametreler farklı sınıflandırma metotlarında kullanılarak otomobil modellerinin tanınması ve bu yöntemlerin tanımadaki başarı oranlarının karşılaştırılması yapılmıştır.

3.1. Materyal

3.1.1. Çalışmada kullanılan araçlar

Deney çalışmasında, ses kayıt işlemi farklı zaman aralıklarında, fazla sayıda ses verisi ile yapıldığı için ve çalışma ortamı açık ortam olup ses yoğunluğundan etkilenmemek adına en uygun ses kaydının alınacağı zamanların da geç saatler olacağı dikkate alınarak çalışmada kullanılan araçların seçiminde erişimi kolaylıkla sağlanabilecek araçlar seçilmiştir. Çalışmada 5 farklı tipte ve modelde araç kullanılmıştır. Çalışmada kullanılan araçların özelliklerinden aşağıda bahsedilmiştir;

1. Renault Symbol 1.5 dci Joy model, 90 hp, 1461 cm³ motor hacminde, 220 Nm torka sahip ve yakıt tipi dizel olan Sedan kasa tipinde bir araç (1. araç),



Şekil 3.1. Çalışmada kullanılan 1. araç (Renault Symbol)

- Renault Fluence 1.5 dci Touch model, 90 hp, 1461 cm³ motor hacminde, 200 Nm torka sahip ve yakıt tipi dizel olan Sedan kasa tipinde bir araç (2. araç),



Şekil 3.2. Çalışmada kullanılan 2. araç (Renault Fluence)

- Peugeot 207 1.4 hdi Active model, 70 hp, 1360 cm³ motor hacminde, 160 Nm torka sahip ve yakıt tipi dizel olan Hatchback kasa tipinde bir araç (3. araç),



Şekil 3.3. Çalışmada kullanılan 3. araç (Peugeot 207)

- Peugeot Partner Van 1.9 Kombi model, 71 hp, 1867 cm³ motor hacminde, 125 Nm torka sahip ve yakıt tipi dizel olan camlı van- kamyonet kasa tipinde araç (4. araç),



Şekil 3.4. Çalışmada kullanılan 4. araç (Peugeot Partner Van)

5. Opel Zafira 1.6 Comfort model, 105 hp , 1598 cm³ motor hacminde, 150 Nm torka sahip ve yakıt tipi benzin olan çok amaçlı geniş kasa tipinde araç (5.araç)



Şekil 3.5. Çalışmada kullanılan 5.araç (Opel-Zafira)

olmak üzere tez çalışmasında 5 farklı tipte ve modelde araç kullanılmıştır.

3.1.2. Çalışmada kullanılan ses kayıt cihazı

Çalışmada kullanılan ses kayıt cihazı, Sony ICD-PX240 marka ses kayıt cihazıdır. Ses kayıt cihazının kolay ve pratik kullanımı sayesinde ses kayıtları alınarak bilgisayar ortamına USB bağlantı kablosu sayesinde aktarılmıştır. Aşağıda ses kayıt cihazının teknik özellikleri belirtilmiştir.

Sony ICD-PX240 Ses Kayıt Cihazı Teknik Özellikler

- Boyut; 38,5x115,2x21,3 mm
- Ağırlık; 72 gr
- 4 gb dahili bellek
- Mono dahili mikrofon
- MP3 kayıt formatı
- Düşük kesim filtresi
- 1043 saat kayıt
- Gürültü kesme özelliği
- 44100 Hz frekans örnekleme oranı




Şekil 3.6. Ses kayıt cihazı

3.1.3. Ses verilerinin alınması

Ses verilerinin alınması aşamasında, yukarıdaki kısımda da bahsedildiği gibi 5 farklı modeldeki otomobil kullanılmıştır. Bu otomobillerden ses kayıtları ilk olarak farklı zaman dilimlerinde sabah, öğle, akşam, gece saatlerinde alınmıştır. Ancak gündüz ve öğle zamanlarında alınan ses kayıtlarında trafik, kuş, insan vs. gibi istenmeyen seslerin etkisinin fazla olması dikkat çekmiştir. Ayrıca ses kayıtlarının yalıtımlı ve kapalı bir ortamda alınamayıp, açık bir ortamda alınabilecek olması, dış ortam vb. seslerin olabildiğince önlenebileceği bir zaman diliminde ses kayıtlarının alınmasını gerekli kılmıştır. Dış ortam vb. istenmeyen ses faktörlerin engellenmesi ve deney düzeneğinin açık ortamda bulunması sebebiyle gece saatleri ses kayıtları için en uygun zaman dilimi olarak belirlenmiştir. Bu nedenle ses kayıtları gece saatlerinde alınarak ses verilerinden amaca uygun istenilen nitelikte bir sonuç elde edilmiştir.


Ses kayıt aşamasında, ses kayıt cihazının yerleşimi ile ilgili standartlar incelenmiştir. ISO 1996 uluslararası standardı, iç ve dış mekanlarda yapılan ses ölçümleri sırasında ses kayıt cihazının konumu ile ilgili yönlendirici bilgiler içermektedir. Ses kayıt cihazının yerleştirileceği konum ölçüm amacına bağlı olarak değişiklik göstermesine rağmen genellikle iç ve dış mekan ölçümlerinde mikrofon veya

ses kayıt cihazının yerden 1.2-1.5 m yüksekte olması gerektiği görülmüştür (Aydın 2008).




Şekil 3.7. Ses ölçümlerinde ses kayıt cihazının yerden yüksekliği (Aydın 2008)

ISO 1996 standardı baz alınarak, ses kayıt işlemi yerden 1.2 m yükseklikten yapılmış, her bir araçtan gece saatlerinde ve aynı açık ortamda, kaput açık halde iken elle ortalama 10 sn süre ile 50'şer adet ses kaydı alınmıştır.




Şekil 3.8. Ses kayıt cihazı konumu (örnek olarak ses kayıt işlemi göstermek amacıyla ve görüntünün net olması için gündüz çekilmiştir)



Şekil 3.9. Ses kayıt işlemi (ses kayıt işlemini göstermek amacıyla ve görüntünün net olması için gündüz çekilmiştir)

Ses kayıt cihazı ile ses kayıt esnasında oluşan farklı süreler (10-12 sn aralığı) dikkate alınarak, her ses kaydı verileri Audacity programı kullanılarak 10 sn uzunlukta olacak şekilde kısıtlanmıştır ve sesler .mp3 formatından .wav formatına dönüştürülmüştür. .wav formatına dönüştürülen tüm ses dosyaları Matlab programında uygun bir şekilde işlenebilmeleri amacıyla .mat uzantılı dosyalara çevrilmiştir.




Şekil 3.10. Audacity programında ses verileri üzerinde yapılan işlemler

Bu çalışmada alınan ses kayıtları 10'ar saniyelik süreler içermekte olup, her araç için 50 adet ses kaydı bulunmaktadır ve sinyaller 44100 Hz örnekleme frekansına sahiptir. Kayıt edilen bu ses sinyallerinden öznitelikler oluşturularak ses verileri sınıflandırılmıştır.

3.2. Metot

3.2.1. Öznitelik vektörlerinin çıkarılması

Öznitelik vektörlerinin çıkarım amacı, verinin tanınması için tanınması istenen nesneye özgü karakteristik bilgilerin tespit edilmesidir. Ses tanıma sistemlerinde öznitelik çıkarmak önemlidir (Altınörs vd. 2008). Eğer özellikler iyi seçilmezse sınıflandırma işlemi başarısız olmaktadır. Örüntülerin tanımlanmasında vektörler kullanılır. Örnek olarak 3x4 boyutunda matris yapısına sahip bir veri tabanında öznitelik çıkarımı aşağıdaki Şekil 3.11'de verilmiştir.



Şekil 3.11. L alfabetik örüntüsü ve öznitelik vektörü (Türkoğlu ve Aslan 1996)

Öznitelik vektörleri çıkarılırken, tanıma yapılması hedeflenen ilgili nesnenin belirgin özelliklerini kapsayan en az miktarda vektör bulunmalıdır. Öznitelik vektörleri çıkarımı yapılmasındaki amaçlar, sınıflandırma işlemini yaparken sınıflama süresini azaltmak, öznitelik vektörünün adından da anlaşılacağı üzere hedefe yönelik belirleyici özelliklerin çıkarılması sayesinde daha az miktarda bilginin işlenmesi, tanımlama yapacak olan karar verici sistemin daha güvenilir işlem yapması ve başarı oranını arttırmaktır (Altınörs vd. 2008).

Giriş ses verisi faydalı faydasız olmak üzere birçok veri içermektedir. Bu nedenle ses tanıma işleminde faydalı bilgi seçilmelidir. Faydalı bilgi demek, veriler cisme yada tanıma yapılacak olan maddeye bağlı özellikleri içermeli ve örüntüleri birbirinden ayırtmaya yeterli olmalıdır (Nabiyev 2012).

3.2.1.1. Spektral analiz

Spektral analizin amacı, durağan rastgele ve sonlu uzunluğa sahip bir sinyalin frekans bandı üzerindeki güç dağılımını tahmin etmektir. Spektral analiz sonlu, ardışık ve değişmeyen verilerin gücünün, frekans üzerinde nasıl dağıldığını göstermektedir. Spektral analizde incelenecek veriye ait olan, tekrarlanan ve gizli olan davranışların ortaya çıkarılması amaçlanmaktadır. Ekonomi, elektromanyetik, haberleşme, astronomi, meteoroloji, radar sistemleri gibi farklı alanlarda spektral analiz yöntemleri kullanılabilir.

Spektral analiz konusunda, klasik yani parametrik olmayan metodlar ve model tabanlı metodlar yani parametrik metodlar olmak üzere iki farklı yaklaşım vardır. İncelenmekte olan sinyal hakkında az miktarda bilgi bulunan uygulamalarda parametrik olmayan metodlar kullanılmaktadır. İncelenmekte olan sinyal üzerinde herhangi bir varsayımın yapılmadığı spektral kestirim metodları klasik metodlar olarak adlandırılmaktadır. Korrelogram, periodogram, Blackman- Tukey, Welch, Barlett yöntemleri klasik metodlardandır (Übeyli 2004).

Parametrik yani model tabanlı metodlarda, veriye ait bir model varsayılır. Bu model spektrumun parametrelerini ifade etmektedir ve spektral tahmini varsayılan modelin parametrelerinin tahminine dönüştürür. Varsayılan model, gerçek veriyi tamamlarsa o durumda parametrik yöntemler daha etkilidir. Model doğru seçildiği takdirde doğru kestirimler birkaç veriden elde edilebilir. Parametrik yöntemler sinyaller için modeller oluşturur ve oluşturulan bu modellere özgü parametreler üretirler. Model tabanlı metodlarda verinin, ortalama otokorelasyon, güç spektrum yoğunluğu gibi bilinmeyen parametrelerinin kestiriminde elde edilen bir örnek veri aralığı alınarak yapılacak kestirimler kullanılabilir. Bu nedenle model tabanlı metodlarda model doğru seçilmiş ise kısa kayıt edilen veriler ile doğru kestirimler yapılması mümkündür (Übeyli 2004). Sinyal, oluşturulan model için gerekli özellikleri sağlarsa parametrik yöntemler daha iyi performans göstermektedir. Eğer böyle bir durum oluşmazsa parametrik olmayan yöntemler tercih edilmektedir. Ayrıca parametrik yöntemler uzun süreli kayıtlarda tercih edilmemektedir. Bu nedenle spektral tahminlerde parametrik olmayan yöntemlerin kullanılması daha uygun denebilir (Mikaeili 2015).

Spektral analiz yöntemleri konuşma tanımada, ses birleşiminde kullanılabilir. Konuşma analizinde ses sinyalinin spektral analizi ses üretim süresinin anlaşılmasına yardımcı olmaktadır. Radar sistemlerinde sinyallerin spektral analizleri kaynak veya istenen hedefe ait konum bilgilerinin elde edilmesini sağlarken, örneğin sismoloji alanında bir deprem sırasında alınan sinyalin spektral analizi yerin hareketi ile ilgili bilgiler sağlayabilmektedir. Yapılan çalışmada olduğu gibi ses tanımada kullanılan klasik spektral analiz yöntemlerinden diğer bölümde bahsedilmiştir.

3.2.1.2. Güç spektral yoğunluğu

Güç spektral yoğunluğu, sinyalin frekans bandı üzerindeki güç dağılımı olarak tanımlanabilmektedir. Bir sinyalin gücü, o sinyalin karesi alınarak hesaplanmaktadır. Ancak Fourier dönüşümü olmayan bir sinyalin spektral yoğunluğu, oto ilinti ($R(t)$) fonksiyonunun Fourier dönüşümü alınarak hesaplanır. Güç spektral yoğunluğu denklemi aşağıda verilmiştir (Bayrak 2012).

$$S(f) = \int_{-\infty}^{\infty} R(\tau) e^{-2\pi\tau f} d\tau = F(R(\tau)) \quad (3.1)$$

Güç spektral yoğunluğu, kovaryans dizisinin ($r(k)$) kısa zamanlı Fourier dönüşümü olarak tanımlanmaktadır. ($\phi(w)$);

$$\phi(w) = \sum_{k=-\infty}^{\infty} r(k)e^{-jwk} \quad (3.2)$$

Güç spektral yoğunluğun diğer bir tanımı ise, birinci tanımın varsayım altındaki ifadesi olarak gösterilmektedir. Denklem 3.3'de gösterilmektedir.

$$\phi(w) = \lim_{n \rightarrow \infty} E \left\{ \frac{1}{N} \left| \sum_{n=1}^N x(n)e^{-jwn} \right|^2 \right\} \quad (3.3)$$

Parametrik olmayan güç spektral yoğunluğu bulma yöntemleri korrelogram ve periodogram olmak üzere ikiye ayrılmaktadır. Korrelogram güç spektral yoğunluğunun ilk tanımından, periodogram ise güç spektral yoğunluğunun ikinci tanımından türetilmektedir (Bayrak 2012). Sinyal genişliği yeterli düzeyde olduğu taktirde bu yöntemlerle spektral analiz yapılabilir. Bu yöntemlerin varyansları yüksektir. Periodogram, güç spektral yoğunluğunun ikinci tanımına dayanır. Bir noktadan sonsuz toplamların kesilmesi ve olasılığın azalması ile ifade edilmektedir.

$$\phi_p(w) = \sum_{n=1}^N x(n)e^{-jwn} \quad (3.4)$$

Korrelogram ise güç spektral yoğunluğunun birinci tanımına dayanır. Aşağıdaki Denklem 3.5'de gösterilmiştir.

$$\phi_c(w) = \sum_{k=-(N-1)}^{N-1} r(k)e^{-jwk} \quad (3.5)$$

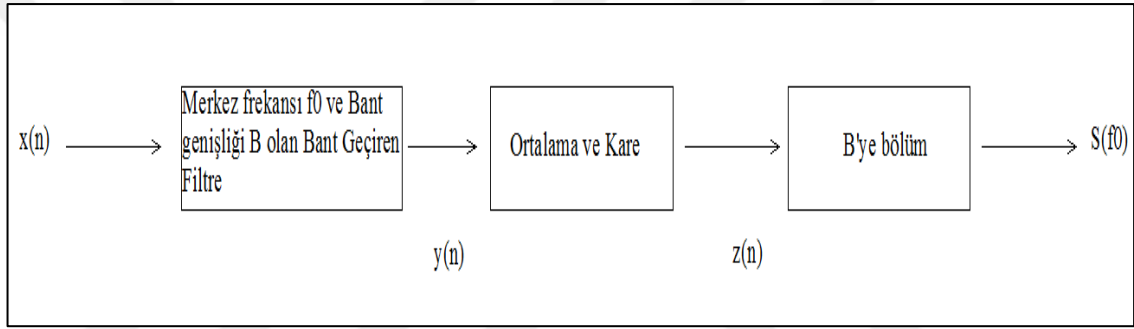
3.2.1.3. Welch yöntemi

Güç spektral yoğunluklarının hesaplanması için Welch yöntemi 20 yılı aşkın süredir yaygın olarak kullanılmaktadır. Welch yöntemi ilk olarak 1961'li yıllarda ortaya çıkmıştır. Daha sonra 1967'li yıllarda ise Welch yöntemini özetleyen dört sayfalık bir rapor oluşturulmuştur. Welch yönteminin yaygın bir kabulünün sebebi fourier dönüşümü kullanmasıdır ve bu durumda hesaplamayı verimli kılmaktadır. Birçok program ve bilimsel yazılım kütüphaneleri Welch yöntemini içermektedir. Bu yazılımlara; Matlab, Matfor, dijital spektral analiz, sinyal işleme algoritmaları vb. uygulamalar örnek verilebilir (Solomon 1991). Spektral analiz yönteminin uygulaması veri değerleri veya örnekler dizisi ile başlamaktadır.

$$x(0), x(1), \dots \dots \dots, x(N-1) \quad (3.6)$$

Veri dizisinin bağımsız değişkeni 0 ile N-1 arasında değişmektedir. Veri değerleri x(n), örnek numarası n ile indekslenir. Bu değer sıralamanın başlangıcına göre örnek bir değer konumudur. Veri örnekleri sabit bir oranda elde edilir. İki ardışık veri

örneği $x(n)$ ve $x(n+1)$ arasındaki süre T saniyedir. Örnekleme oranı $1/T$ 'dir. Veri dizisinin saniye cinsinden uzunluğu $T_{dizi} = N.T$ 'dir. Bir veri değerinin elde edilme zamanı $t=t_0+nT$ örnek sayısı ile ilintilidir. Burada t_0 ilk veri örneğinin elde edildiği süredir. Spektral analizin amacı, verileri ağırlıklı sinüzoidlerin toplamına ayırmaktır. Bu ayrışma, incelenen olgunun frekans içeriğini değerlendirmeyi sağlamaktadır. Spektral analiz iki majör alana ayrılmaktadır. Bunlardan biri güç spektrum yoğunluğunun diğeri ise fourier dönüşümünün hesaplanmasıdır. Veriler rastgele etki veya gürültü içermediğinde, deterministik olarak ifade edilir ve fourier transformu ile hesaplanır. Rastgele bir etki olduğunda ise güç spektrum yoğunluğu hesaplanmaktadır. Tek bir sabit frekansta f_0 , güç spektrum yoğunluğunun nasıl tahmin edileceği aşağıdaki şekilde gösterilmektedir. Bu yöntem Blackman ve Tukey tarafından oluşturulan direkt analog hesaplama olarak ve Gardner tarafından oluşturulan dalga analizi olarak adlandırılmaktadır. Konsept olarak, güç spektrum yoğunluğu tahmininin tasarımı, bant geçiren filtre tipi, filtrenin band genişliğinin seçimi, band geçiş filtresi çıkış verilerinin ortalamasını ve karesini alma yöntemi ile ilişkilidir.



Şekil 3.12. Güç spektral yoğunluğu tahmininde dalgacık analizi yöntemi (Solomon 1991)


Güç spektral yoğunluğunun hesaplanmasındaki amaç, $x(n)$ frekans içeriğinin frekansa göre nasıl değiştiğini görmektir. Bunu yapmak için ise Şekil 3.12'deki bant geçiren filtre için birçok farklı merkez frekansı seçilmelidir. Daha sonra bant geçiren filtrenin farklı merkez frekanslarına karşı $S(f)$ - f grafiği çizilir. Tek bir sabit frekans f_0 'da tek bir güç spektral yoğunluğu değerini tahmin etmeye çalışan bir örnek incelenecek olursa, f_0 frekansının tek sabit bir frekans olduğunu bize hatırlatması için 0 değerinin kullanıldığı varsayalım. Band geçiren filtrenin ideal olduğu yani bant geçişlerinde 1 değerinin elde edildiği, başka yerlerde ise 0 olduğu düşünülürse, bant geçiren filtre veri dizisini $f_0-B/2$ ile $f_0+B/2$ Hz aralığında bir frekans bandında sınırlar. Bant geçiren filtre $x(n)$ 'nin DC bileşenini kaldırır. Bant geçiren filtrenin çıkışı $y(n)$ sifıra yaklaşır. $y(n)$ ortalama değeri yaklaşık sıfır olur. Şekil 3.12'deki $z(n)$ ise bant geçiren filtre çıkışı $y(n)$ 'nin çıkışının karesinin ortalama değeridir yani $y(n)$ 'nin ortalama kare değeri olarak adlandırılabilir. $x(n)$ giriş dizisinin frekans içeriğine bağlıdır. $z(n)$, yalnızca $y(n)$ dizisi sıfır olduğunda sıfır olabilir. Örneğin, $x(n)$ sinüs dalgası frekansı $f_0-B/2$ 'den az olursa bu durumda bant geçiren filtre çıkışının karesinin ortalama değeri $z(n)$ sıfır olur. Eğer $x(n)$ frekansı f_0 olan bir sinüs dalgası ise bu durumda $z(n)$ sıfır olmayan bir dizidir. $z(n)$ 'nin değeri, $f_0-B/2$ ile $f_0+B/2$ Hz arasında kalan sinüs dalgalarının gücü ile orantılıdır.

Bant geçiren filtre ve ortalama seçimi, birbirine ve veri dizisinin uzunluğu ile ilişkilidir. Ancak bant geçiren filtre ve ortalama seçiminde bazı kısıtlamalar da mevcuttur.

$$T_{dizi} \geq T_{ort} \gg \frac{1}{B} \quad (3.7)$$

Denklem 3.7’de, T_{dizi} = saniye cinsinden veri dizisi uzunluğu, T_{ort} =saniye cinsinden ortalama süre, B ise bant geçiren filtrenin Hz cinsinden bant genişliğidir. Buradaki kısıtlama $T_{dizi} \geq T_{ort}$ denkleminde yola çıkarak veri dizisinin uzunluğunun ortalama süreye eşit veya daha büyük olması gerektiğidir. Yani veri ortalaması alınmadan önce elde edilmelidir. Rastgele varyasyonların azaltılması için ise bağımsız verilerin ortalaması gereklidir. Örnek verilecek olursa, bir konu hakkında bir kişiye evet hayır sorusu sorulduğunu düşündüğümüzde, konu hakkında bir bilgi elde etmek amacıyla yalnızca evet hayır soruları sormak yeterli bilgi edinmemize yardımcı olmaz. Ancak farklı soruların sorulması ile daha doğru bir sonuç alınır. Bu sayede sorulan farklı sorulara karşılık alınan farklı cevaplara göre elde edilen ortalama doğru cevap sayısı ile konuya dair bilgi edinme şansı artmaktadır. Aynı soruyu tekrar tekrar sormak konu hakkında yeni bir bilgi sağlamadığı için bir kazanç sağlamaz. Aynı soru sorularak alınan aynı cevapların ortalamasını tekrar tekrar almak rastgele gürültüyü düzeltmemektedir. Her yeni sorunun cevabı ise konu hakkında daha fazla bilgi edinmeyi sağlamaktadır. Bu durumda bağımsız verilerden elde edilen ortalama rastgele değişimleri azaltmaktadır.

Çok kısa bir darbe, bant geçiren filtrelili olduğunda sonuç genliği zamanla değişen bir sinüs dalgasıdır. Bu sonuca filtrenin impuls yanıtı denir. Şekil 3.13’de bir bant geçiren filtrenin giriş ve çıkışları gösterilmektedir. Filtre, $f = 210$ Hz’lik bir merkez frekansına ve $B = 20$ Hz’lik bir 3 dB bant genişliğine sahiptir. Genlik modülasyonlu sinüs dalgasının uzunluğu yaklaşık $1/B = 0.05$ saniyedir. $T_{ort} = 1/B$ olduğunda ortalama alma, rastgele etkileri düzenlemeye başlar. Etkili düzenleme için $T_{ort} \gg 1/B$ olmalıdır. Yani ortalama süre sinyalin uzunluğundan çok daha uzun olmalıdır. Şekil 3.13’de bulunan alt grafikteki sıfırdan farklı veri değerlerinin tümü üst grafikteki sıfıra eşit olmayan tek sıfır gibi gözükenden üretilmiştir.



Şekil 3.13. Bant geçiren filtre tepkisi (Solomon 1991)

İlk sıfırdan farklı veri değerinden yaklaşık $1/B$ saniye sonra bant geçiren filtre ilk veri değerine cevap verir. İlk sıfırdan farklı veri değerinden yaklaşık $1/B+T$ saniye sonra bant geçiren filtre ikinci veri değerine cevap verir. Genel olarak ilk sıfırdan farklı veri değerinden $1/B+(n-1)T$ saniye sonra bant geçiren filtre n . veri değerine yanıt vermiş olur. Bant geçiren filtre çıktısının iki komşu değeri $y(n)$ ve $y(n+1)$ hemen hemen aynı bilgileri içerir yani aynı girdi değerlerine cevaptır denebilir. $y^2(n)$ değerleri birbirleri ile $1/B$ saniyeden daha yakın ilişkilidir. Rastgele etkiler düzenlemek için ise $y^2(n)$ 'nin bağımsız değerlerinin ortalaması alınmalıdır. İyi bir güç spektrum yoğunluğu elde etmek için $y^2(n)$ 'nin birçok bağımsız değerinin ortalamasının alınması gerekmektedir (Solomon 1991).

Şekil 3.12'de görülen akış şeması birçok farklı yolla da yapılabilir. Aşağıdaki denklemler ile Welch yöntemi tanımlandıktan sonra Şekil 3.12'de bulunan akış şeması ile olan bağlantısı da açıklanacaktır. Welch yöntemindeki adımlar şu şekildedir (Solomon 1991);

Veri dizisinin bölünmesi;

$$x(0), x(1), \dots, x(N-1) \quad (3.8)$$

Gruplarına veya K . Segmentine bölersek;

$$\text{Segment 1: } x(0), x(1), \dots, x(M-1) \quad (3.9)$$

$$\text{Segment 2: } x(S), x(S+1), \dots, x(M+S-1) \quad (3.10)$$

$$\text{Segment } K: x(N - M), x(N - M + 1), \dots, x(N - 1) \quad (3.11)$$

Segmentlerde bulunan M ; her segmentteki veya küme büyüklüğündeki nokta sayısı, S ; segmentler arasında geçiş yapılacak nokta sayısı, K ; segment veya küme sayısıdır.

$k=1$ ile K arası her segment için, $v = i/M$, $-(M/2 - 1) \leq i \leq M/2$ aralıklı frekansta pencereleme uygulanmış ayrık fourier dönüşümü hesaplanırsa;

$$X_k(f) = \sum_m x(m)w(m) \exp(-j2\pi vm) \quad (3.12)$$

Burada; $m = (k - 1)S, \dots, M + (k - 1)S - 1$ ve $w(m) =$ pencereleme fonksiyonudur. $k=1$ ile K arası her segment için, periodogram $P_k(f)$ değerini oluşturmak için ayrık fourier dönüşümünden faydalanılırsa;

$$P_k(f) = \frac{1}{W} |X_k(f)|^2 \quad (3.13)$$

$$W = \sum_{m=0}^M w^2(m) \quad (3.14)$$

Periodogram değerlerinin ortalaması alınarak ise güç spektrum yoğunluğunun Welch yaklaşımı elde edilir;

$$S_x(f) = \frac{1}{K} \sum_{k=1}^K P_k(f) \quad (3.15)$$

Welch yöntemi, periodogram ortalama metodu veya ağırlıklı örtüşen segment ortalaması yöntemi olarak da adlandırılmaktadır. M parametresi her segment için uzunluğu ifade eder. M parametresine küme büyüklüğü de denebilir. M ayrık fourier dönüşümünün uzunluğudur. S parametresi segmentler arasında geçiş yapılacak nokta sayısıdır. Her segment veya kümedeki yeni noktaların sayısıdır. İki komşu segment arasındaki ortak nokta sayısı $M-S$ 'dir. $S=M$ olduğundan segmentler arasında üst üste binme olmaz. $S=0.5M$ olduğunda ise segmentler arasında %50 oranında örtüşme meydana gelir. M nokta dizisi, $w(m)$ ise pencereleme fonksiyonudur. Hamming, Blackman, Blackman-Harris, Kaiser-Bessel, Hann gibi yaygın kullanılan pencereleme işlemlerinin çoğu dikdörtgen pencerelemedir. K parametresi ise segment veya kümelerin sayısıdır. $S_x(f)$ ise güç spektrumu tahminini oluşturmak için bir araya gelen ortalama periodogram sayısıdır.

Bu durumda welch yöntemini özetlememiz gerekirse, bu yöntem güç spektrum yoğunluğunun geliştirilmiş bir tahmincisidir. Zaman dizisi vektörlerinin segmentlere bölünmesini, her segmentin değiştirilmiş bir periodogramının hesaplanmasını ve ardından güç spektrum yoğunluğu tahminlerinin ortalamasını içermektedir. Sonuç, Welch yönteminin güç spektrum yoğunluğu tahminini oluşturur. Değiştirilmiş periodogramların ortalaması, tüm veri kaydının tek bir periodogram tahminine göre tahminin varyansını azaltma eğilimindedir. Segmentler arasındaki üst üste binme gereksiz bilgi ortaya çıkarmasına karşın dikdörtgen olmayan bir pencere kullanımı ile üst üste binme etkisini azaltır.

Kısa veri kayıtlarının ve dikdörtgen olmayan pencerelerin birleşik kullanımı, tahmin edicinin azaltılmış çözünürlüğüyle sonuçlanır. Özet olarak, varyans azaltımı ve çözünürlük arasında bir fark vardır. Özellikle sinyal gürültü oranı düşük olduğunda periodograma göre gelişmiş tahminler elde etmek için welch yöntemi kullanılabilir.

Çalışmada, Hamming pencereleme ve welch yöntemi kullanılarak güç spektrum yoğunlukları hesaplanmıştır ve her ses verisine ait ayrı ayrı güç spektrum yoğunluklarının grafikleri çizdirilmiştir. Güç spektrum yoğunluk grafiklerinin ayrı ayrı incelenmesi sonucunda 26, 27, 28-32, 51-52, 54, 55, 59-61, 76-77, 80, 85, 107, 113, 133, 230-235, 266-273, 320, 411-425 Hz'lik frekans değerlerinde farklılıklar tespit edilmiş ve bu frekans değerlerine karşılık gelen güç spektral genlik değerleri öznitelik olarak belirlenmiştir. Daha sonra aşağıdaki bölümde belirtilen sınıflandırma yöntemleri kullanılarak sınıflandırma işlemi yapılmıştır. Ayrıca belirtilmelidir ki bazı bölgelerde frekans aralıkları (230-235, 59-61 vb.) görülmektedir. Bu frekans aralığına sahip bölgelerde maksimum genlik değerleri öznitelik olarak alınmıştır.

3.2.2. Sınıflandırma yöntemleri

3.2.2.1. Yapay sinir ağları (YSA)

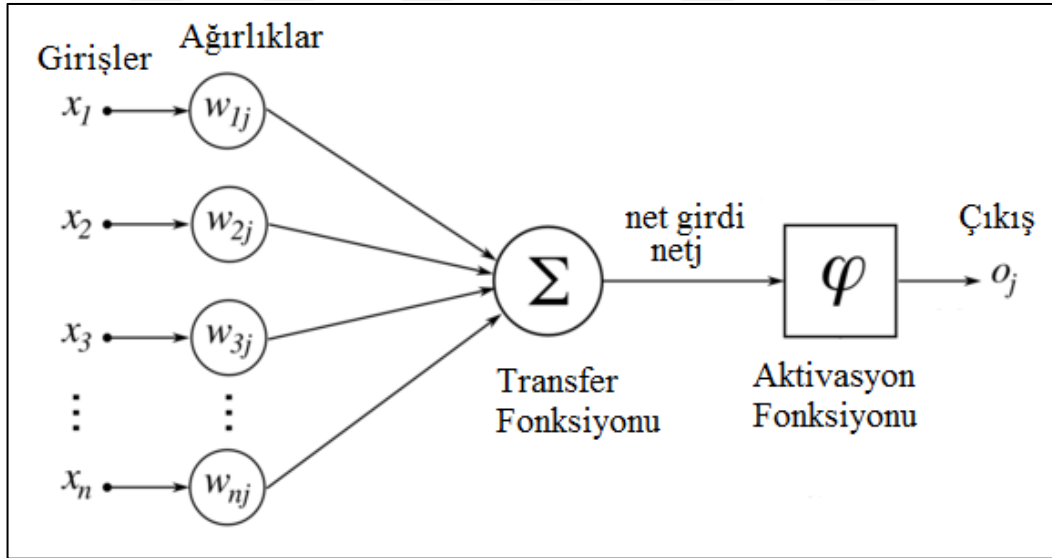
Yapay sinir ağları, insan beyninin çalışma sisteminin yapay olarak benzetimi sonucu ortaya çıkmıştır. Genel olarak yapay sinir ağları, insan beynindeki bir çok nöronun (sinir hücresi) ya da yapay olarak basit işlemcilerin birbirlerine değişik etki seviyelerinde bağlanması sonucu oluşan karmaşık bir sistem olarak tanımlanabilir. Yapay sinir ağları genelde çok farklı yapıda ve formda bulunan veri yapılarının hızlı bir şekilde tanımlanması ve algılanması üzerine kullanılmaktadır. YSA'lar örneklerle ilgili bilgiler toplamakta, genellemeler yapmakta ve daha önce görmediği örnekler ile karşılaştırıldığında öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. Günümüzde yapay sinir ağları, kontrol ve sistem tanımlama, görüntü ve ses tanıma, tahmin ve kestirim, arıza analizi, tıp, haberleşme vb. alanlarda geniş bir kullanım alanına sahiptir. Yapay sinir ağlarının günümüzde yaygın kullanımının en önemli sebebi klasik yöntemlerle çözümü zor olan karmaşık problemlerin başarılı bir şekilde çözümüne olanak sağlamasıdır (Türkoğlu ve Aslan 1996).

Sinir ağlarında giriş sinyallerini alan, yorumlayan ve uygun çıktıya ileten işlemciler nöron adı verilir. Bir nöron, soma olarak adlandırılan hücre gövdesi, gövdeye giren sinyal alıcıları (dendrit) ve gövdeden çıkan sinyal iletici (akson) olmak üzere üç kısımdan oluşur (Sağiroğlu vd. 2003). Hücre gövdesi (soma), hücreyi denetler ve hücre etkinliklerinin tümünü yönetmekle sorumludur. Dendritler, sayısal olarak

birden fazla olabilen ve nörona bilgiyi alan, iç yapıları nöronlarla aynı olan yapılardır. Aksonlar, dendritten aldıkları bilgileri diğer hücrelere aktaran elemanlardır. Her nöronun yalnızca bir aksonu vardır. Yapay sinir ağları bu biyolojik sinir ağlarından esinlenerek birbirine bağlı doğrusal ya da doğrusal olmayan birçok işlemci elemandan oluşmaktadır. Bir yapay nöron temel olarak giriş, ağırlık, toplam fonksiyon, aktivasyon fonksiyonu ve çıkış olmak üzere 5 kısımdan oluşmaktadır (Aydın 2005).

Giriş, yapay hücreye dışarıdan gelen ve ağırlık öğrenmesi istenen bilgilerdir. Ağırlıklar, yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Toplama fonksiyonu, hücreye gelen net girdiyi hesaplamaktadır. Net girdiyi hesaplamak için farklı fonksiyonlar kullanılmasına rağmen en yaygın kullanılan ağırlıklı toplamı bulmaktır. Bu fonksiyonda her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece net gelen girdi bulunmuş olur. Aktivasyon fonksiyonu, hücreye gelen net girdiyi işleyerek bu girdiye karşılık hücrenin üreteceği çıktıyı belirlemektedir. Aktivasyon fonksiyonunun kullanım amacı, zaman söz konusu olduğunda toplama işlevinin çıkışının değişmesine izin vermesidir. Aktivasyon fonksiyonunun seçimi, yapay sinir ağının verilerine ve öğrenilmesi istenen veriye bağlıdır.

Hücre çıktısı ise aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dışarıda kullanılır yada bir başka hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir. Nöronun çıkan tek bir çıktı değeri bulunur. Ancak aynı değer birden fazla nörona girdi olarak gider. Şekil 3.14’de basit bir nöron modeli görülmektedir.



Şekil 3.14. Basit nöron modeli (Uslu (2016)’dan değiştirilerek alınmıştır)

Bütün sinir ağı modellerinde giriş değerleri (x), ağırlık değeri (w) ile çarpılarak toplanır. Ağırlıklandırılmış girişlerin toplamı nöronun çıkış değerini verir.

$$netj = \sum_{i=1}^n x_i w_{ij} \quad (3.16)$$

Denklem 3.16'de x_i sinyali kendine ait olan katsayı ile çarpılarak toplam sinyale eklenmektedir. "net" şeklinde toplanan değer çekirdek tarafından akson kullanılarak sinapsise gönderilmektedir. Sinapsis ise gelen toplam sinyal değerini eşikleyerek çıktı değerini verir.


$$o_j = f(\text{net}_j) \quad (3.17)$$

Denklem 3.17'de f ; aktivasyon fonksiyonu olarak gösterilmektedir. Bu fonksiyon, nöron modelinin bir dizi aktivasyon değerini içermektedir. f fonksiyonu, matematiksel herhangi bir fonksiyona denk olabilir. Yapay sinir ağlarında aktivasyon fonksiyonları nöronun çıkış genliğini istenen değerler arasında sınırlamaktadır. Sınırlama genellikle $[0,1]$ veya $[-1,1]$ değerleri arasında yapılır. İşlemlerde kullanılacak olan aktivasyon fonksiyonunun türevi alınabilir olmalıdır. Yapay sinir ağlarında katmanlar arasında genellikle Hiperbolik Tanjant (tansig), Lineer (purelin) ve Sigmoid (logsig) aktivasyon fonksiyonları kullanılmaktadır.

- Hiperbolik Tanjant Aktivasyon Fonksiyonu

Hiperbolik tanjant aktivasyon fonksiyonları giriş uzayının genişletilmesinde kullanılan etkili bir fonksiyondur. Bu aktivasyon fonksiyonunun değişim aralığı $[-1,1]$ aralığıdır ve fonksiyon bu aralıkta doğrusal olmayan bir değişim göstermektedir. Hiperbolik tanjant fonksiyonlarına Tanjant Sigmoid (tansig) fonksiyonları da denilmektedir. Hiperbolik tanjant aktivasyon fonksiyonu tanımı, Denklem 3.18'de verilmiştir.

$$k = \frac{1 - e^{-2a}}{1 + e^{2a}} \quad (3.18)$$




Şekil 3.15. Hiperbolik tanjant aktivasyon fonksiyonu (Sağiroğlu vd. 2003)

- Lineer Aktivasyon Fonksiyonu

Lineer aktivasyon fonksiyonları nöronların girdisini direkt olarak nöron çıkışına veren fonksiyonlardır. Bu fonksiyonlar genellikle yapay sinir ağlarının çıkış katmanında kullanılmaktadır. Lineer aktivasyon fonksiyonlarının değişim aralığı $[-1,1]$ aralığıdır.

Linear aktivasyon fonksiyonu tanımı, Denklem 3.19’da verilmiştir. Denklem 3.19’daki “X” değeri sabit bir katsayıdır.

$$k = X.a \quad (3.19)$$




Şekil 3.16. Linear aktivasyon fonksiyonu (Sağiroğlu vd. 2003)

- Sigmoid Aktivasyon fonksiyonu

Sigmoid aktivasyon fonksiyonlarına Logaritmik sigmoid (logsig) fonksiyonları da denebilmektedir. Sigmoid aktivasyon fonksiyonlarının değişim aralığı $[0,1]$ aralığıdır. Bu aralıkta sigmoid fonksiyonu doğrusal olmayan bir değişim göstermektedir. Sigmoid fonksiyonu tanımı, Denklem 3.20’de verilmiştir.

$$k = \frac{1}{1 + e^{-a}} \quad (3.20)$$



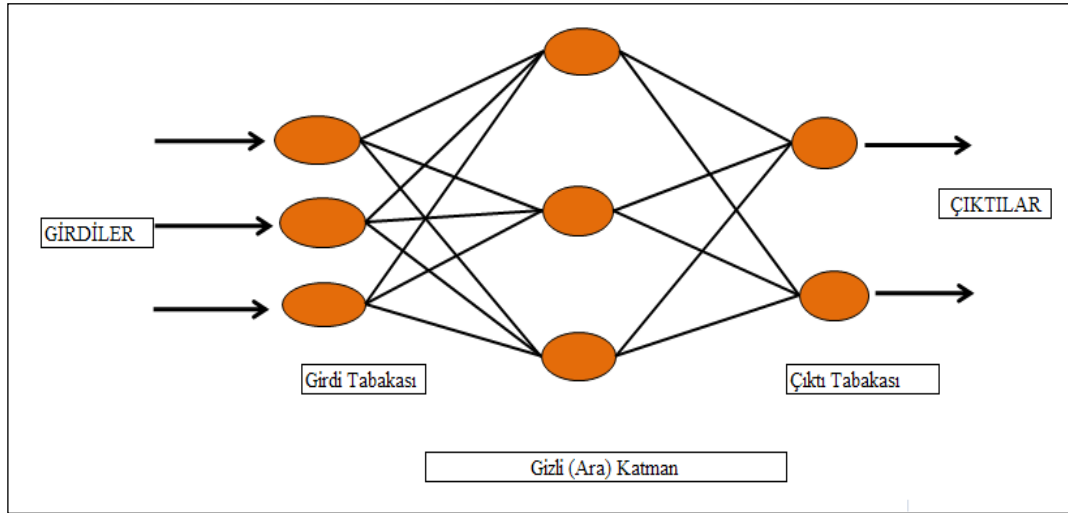
Şekil 3.17. Sigmoid aktivasyon fonksiyonu (Sağiroğlu vd. 2003)

Yapay sinir ağlarının yapısı genel olarak incelendiğinde, milyonlarca biyolojik sinir hücresinin (nöron) bağlantılar aracılığıyla birleşip beyni oluşturdukları gibi, yapay sinir hücrelerinin birleşmesinden de yapay sinir ağları meydana geldiğinden yukarıda bahsedilmiştir. Nöronların aynı doğrultu üzerinde dizilmesi ile katmanlar ve bu katmanların birleşimiyle de yapay sinir ağları oluşmaktadır. Bu sistemdeki nöronlardan

bazıları yalnızca girdileri almak için, bazıları ise çıktıları iletmek için dış mekan ile bağlantı halindedir. Diğer tüm nöronlar ise gizli katmanlardır. Genel olarak sinir hücreleri, girdi katmanı, gizli katman veya ara katman ve çıktı katmanı olmak üzere 3 katman halinde ve her katman içinde paralel biçimde olacak biçimde bir araya gelerek ağı oluştururlar (Öztemel 2006). Bu katmanlar;

- **Girdi Katmanı:** Bu katmandaki nöronlar, dış dünyadan bilgileri alarak gizli katmanlara iletirler. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmaz. Sadece girdi değerlerini bir sonraki katmana iletirler. Bu nedenle bazı araştırmacılar, bu katmanı ağların katman sayısına ilave etmezler.
- **Ara Katman:** Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilir. Bu bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ içinde girdi ve çıktı katmanı tek katmandan oluşabilirken, ara katman birden fazla katmandan oluşabilmektedir. Ara katmanlarda çok sayıda nöron bulunur ve bu nöronlar birbirleriyle bağlantılıdır. Ağın büyüklüğünün tanımlanması ve performansının bilinmesi açısından ara katmanda bulunan nöronların sayısının seçimi oldukça önemlidir.
- **Çıktı Katmanı:** Ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için çıktı üretirler.

Bahsedilen katmanlarda bulunan nöronlar ve bu katmanlar arasındaki ilişkiler Şekil 3.18’de gösterilmektedir. Şekil 3.18’deki yuvarlak turuncu renkteki şekiller nöronları ifade etmektedir. Her katmanda birbirine paralel elemanlar bulunmaktadır. Bu paralel elemanları birbirine bağlayan çizgiler ise ağın bağlantılarını göstermektedir. Nöronlar ve bunların bağlantıları bir yapay sinir ağını oluşturmaktadır.




Şekil 3.18. Bir yapay sinir ağına genel yapısı (Öztemel 2006)

Yapay sinir ağları genel olarak üç ana kritere göre sınıflandırılmaktadır. Bu kriterler; yapay sinir ağlarının bağlantı yapısına göre, öğrenme şekline göre ve katman sayılarına göre. Yapay sinir ağlarının bağlantı yapısı, sinirler arasındaki bağlantıların yönüne göre birbirinden ayrılır ve bazı ağlar ileri besleme ağ yapısı içerirken kimisi ise geri beslemeli ağ yapısı içerir. Öğrenme şekillerine göre yapay sinir ağları ise

danışmanlı, kendi kendine öğrenme (danışmansız) ve destekliyiçi öğrenme olarak ayrılmaktadır. Sınıflandırma kriterlerinden katman sayılarına gelindiğinde ise, yapay sinir ağları tek katmanlı ve çok katmanlı olmak üzere ikiye ayrılmaktadır.


Bağlantı yapısına göre yapay sinir ağları incelendiğinde, bazı ağlar ileri besleme şeklinde iken bazıları geri besleme yapısı içermektedir. İleri beslemeli yapay sinir ağlarında, nöronlar arasındaki bağlantılar döngü oluşturmazlar ve bu ağlar girdi veriye genellikle hızlı bir şekilde karşılık üretir. Nöronlar, genellikle katmanlara ayrılmıştır. Her katmandaki nöronlar bir sonraki ile ilişkilidir. Bilgi akışı, girdi katmanından başlayarak çıktı katmanına doğru geri besleme olmadan tek yönde olur. Şekil 3.19'da ileri beslemeli bir ağ yapısı verilmiştir.



Şekil 3.19. İleri beslemeli ağ yapısı (Öztemel 2006)


Geri beslemeli ağlarda ise, çıktı katmanını ve ara katmandaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Nöronlar arasında geri besleme bağlantıları bulunur. Geri beslemeli ağlarda herhangi bir hücrenin çıktısı girdi katmanına direkt olarak gönderilerek tekrar girdi katmanını olarak kullanılması mümkündür. Geri besleme, hücreler arasında ve nöronlar arasında olabilir. Geri beslemeli yapay sinir ağları, doğrusal olmayan bir davranış gösterir.

Uygulamada ileri beslemeli ağlar, geri beslemeli ağlarla kıyaslandığında daha sık kullanılmaktadır. Bunun nedeni, pratikte geri beslemeli ağların uygulanabilirliğinin zor olmasıdır. Geri beslemeli ağların farklı yapılarla oluşturulabilir olması, belirli bir model yapısında uzmanlaşmasını engelleyebilirken, eğitim algoritmalarının tutarsız olması nedeniyle eğitim aşamasının da zor olmasına neden olabilmektedir, ayrıca geri beslemeli ağların eğitim süreleri uzun zaman almakta ve eğitim kümesindeki veri sayısı arttıkça bu süre daha da uzamaktadır (Altan 2008).



Şekil 3.20. Geri beslemeli ağ yapısı (Öztemel 2006)

İleri beslemeli sinir ağlarında (FFNN), sinirler katman yapısına göre organize olmaktadır. İleri beslemeli sinir ağlarında giriş ve çıkış katmanları mutlaka bulunmaktadır. Giriş katmanında alınan değerler çıkış katmanına aktarılır. İleri beslemeli sinir ağlarında giriş verilerinin oluşturduğu giriş katmanında herhangi bir hesaplama olmadığından toplam katman sayısına dahil edilmez. İleri beslemeli sinir ağları bir veya birden fazla gizli katman içerebilir. Gizli katmandaki sinirlere gizli sinir adı verilir. Giriş katmanını oluşturan giriş vektörleri ikinci katmana doğrudan giriş olarak aktarılmaktadır. Diğer katmanlarda da sistem aynı şekilde devam etmektedir. İleri beslemeli 2 katmanlı bir yapay sinir ağı yapısı Şekil 3.21’de görülmektedir.



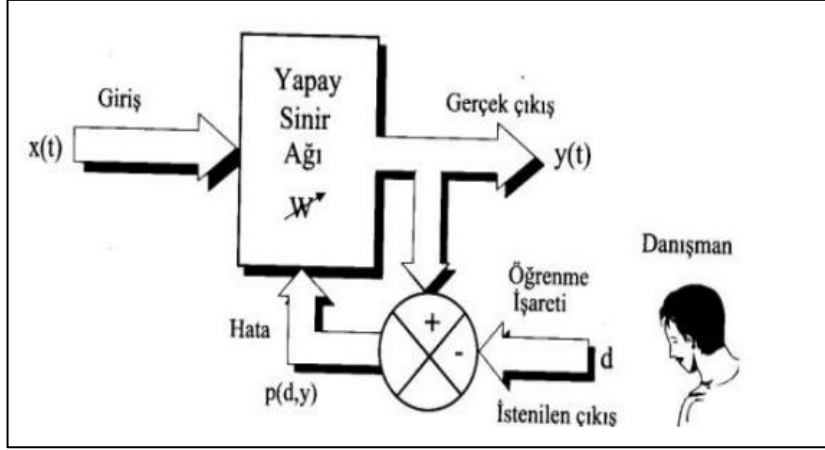
Şekil 3.21. İleri beslemeli 2 katmanlı yapay sinir ağı yapısı (FFNN) (Sokouti vd. 2014)

İleri beslemeli ağlarda bağlantılardan birinde eksiklik olması durumunda, ağa kısmi bağlantılı denilmektedir. İleri beslemeli sinir ağlarında genellikle gizli katman sayısı sınıflandırmada oluşturulabilecek grup sayısını belirlemektedir. K tane gizli katman bulunduran ileri beslemeli sinir k grubunda sınıflandırabilir denebilir (Akşahin 2010). FFNN'lerde hücreler katmanlar şeklinde düzenlenir ve katmanda bulunan hücrelerin çıkışları diğer katmana giriş olarak verilmektedir. Giriş katmanı, dış ortamdan aldığı bilgileri değişikliğe uğratmadan orta katmandaki hücre veya hücrelere aktarır. Alınan bilgi, orta katman ve çıkış katmanında işlenerek ağ çıkışı belirlenir. İleri beslemeli yapay sinir ağları, nesne tanıma, sinyal işleme, sistemlerin tanımlanması ve denetimi gibi yaygın kullanım alanına sahiptir (Toprak 2007).

Yapay sinir ağlarının temel özelliği öğrenme yeteneğidir. Öğrenme, bir olay hakkında gerçekleşmiş örnekleri kullanarak olayın girdi ve çıktıları arasındaki ilişkiyi belirlemek ve bu ilişkiye göre daha sonra oluşabilecek yeni örneklerin çıktıları belirlemektir. Olay ile ilgili örneklerin girdi ve çıktıları arasındaki ilişkinin olayın genelini temsil edebilecek bilgiler içerdiği kabul edilmektedir (Öztemel 2006).


Bir yapay sinir ağına ait nöronların bağlantılarının ağırlık değerlerinin belirlenmesi sürecine ağırlık eğitimi adı verilir. Bu ağırlık değerleri rastgele verilerek öğrenme süreci başlar. Belirlenen örnekler ağa tanıtıldıkça ağırlık değerleri değişir ve bu süreç, ağ istenen çıktıları üretmeye başladığı ana kadar devam eder. Ağ eğitimi, istenen çıktıların üretilip, ağ temsil edilen olayla ilgili genellemeler yapacak duruma geldiğinde tamamlanmış demektir. Bu sürece ağ öğrenmesi adı verilir. Yapay sinir ağlarında öğrenme için iki yaklaşım vardır; danışmanlı ve danışmansız öğrenme.

Yapay sinir ağlarında danışmanlı öğrenmede, yapay sinir ağı ilk olarak öğrenilmesi istenen olayla ilgili eğitilmelidir. Eğitim işleminde olay ile ilgili girdiler ve bu girdiler karşılığında oluşturulması gereken çıktılar sisteme verilir. Giriş bilgisinden üretilen çıktı değeri ile hedef çıktı değeri karşılaştırılarak ağırlıkların değiştirilmesi için gerekli bilgi hesaplanır. Karşılaştırmadan oluşan fark, hata olarak tanımlanır ve bu fark istenen değerden küçük oluncaya kadar eğitim devam eder. Hata değeri istenen değer altına düştüğünde ağırlık değerleri sabitlenir ve eğitim sonlanır. Bu öğrenme yönteminde, öğrenmeye dışarıdan müdahale eden bir danışman bulunmaktadır. Öğrenme danışman kontrolündedir. Danışman eğitim kümesi ve hata değerlerini belirleyerek eğitimin ne kadar süre devam edeceğine karar verir. Bu yöntemin en önemli özelliği ise eğitim esnasında gerçek giriş, çıkış değerlerinin kullanılmasıdır (Ataseven 2013). Şekil 3.22'de danışmanlı öğrenme yapısı görülmektedir.



Şekil 3.22. Danışmanlı öğrenme yapısı (Ataseven 2013)

Kendi kendine öğrenmede ise sistemin öğrenmesine yardımcı olan herhangi bir danışman bulunmamaktadır. Kullanılan girdi vektörlerinin hangi sınıfa ait olduğu sisteme verilmez. Sınıflama işlemi, girdileri birbirleriyle karşılaştırarak sistemin kendisi yerine getirir. Sisteme yalnızca girdi değerleri verilir, hedef çıktıları ise belirtilmez. Sistem girdiler içinde birbirlerine en çok benzeyenleri gruplar ve her bir grup için farklı bir örüntü tanımlamaktadır (Aydın 2005). Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendine öğrenmesi beklenmektedir. Şekil 3.23’de kendi kendine öğrenme yapısı görülmektedir.



Şekil 3.23. Danışmansız öğrenme yapısı (Sağiroğlu vd. 2003)

İleri beslemeli ağlarda kullanılan öğrenme algoritmaları kendisinden önce geliştirilen algoritmalara alternatif olarak ortaya çıkmıştır ve önceki algoritmaların iyi yönlerinin geliştirilmesine yönelmektedir. Algoritmalarından bazıları deneme yanılma tekniklerini kullanırken bazıları da standart sayısal optimizasyon yöntemlerini kullanmaktadır. Newton, Levenberg- Marquardt gibi ikinci dereceden türev gerektiren algoritmalar öğrenme hızını önemli oranda arttırmaktadır. Tez çalışmada, çok katmanlı ileri beslemeli yapay sinir ağları ve öğrenme algoritmalarından sayısal optimizasyon yöntemlerini kullanan Levenberg- Marquardt öğrenme algoritması kullanılmıştır.

Levenberg-Marquardt algoritması doğrusal olmayan en küçük kareler problemlerinin çözümünde standart bir tekniktir. En küçük kareler problemleri, veri noktaları ve fonksiyon arasındaki hataların karelerinin toplamını en aza indirerek ölçülen veri noktalarına bir parametrelili fonksiyonun yerleştirilmesi bağlamında ortaya çıkmaktadır. Eğer fit fonksiyonu parametrelerde doğrusal değilse, en küçük kareler problemi lineer değildir. Doğrusal olmayan en küçük kareler yöntemleri, fonksiyon değerleri ile ölçülen veri noktaları arasındaki hataların karelerinin toplamını, parametre değerlerine yapılan güncellemeler dizisi boyunca yinelemeli olarak azaltır. Levenberg-Marquardt algoritması, Gradyen alçalma metodu ve Newton metodlarının birleşimidir. Gradyen öğrenme algoritmasına alternatif olarak sunulan Newton metodunda, temel adım Hessian matrisini oluşturmaktır. Hessian matrisi karmaşık ve ileri beslemeli yapay sinir ağı için hesaplaması zor bir matristir. Newton yöntemlerinde ikinci derece türev hesabı yapılmadan işlem yapılan bir sınıf mevcuttur. Bu sınıftaki yöntemlere Quasi Newton yöntemleri denir. Quasi Newton yöntemleri, algoritmanın her iterasyonunda, Hessian matrisinin yaklaşık bir şeklini kullanmaktadır (Dursun 2009).

Levenberg Marquardt algoritması da Quasi Newton yöntemleri gibi, Hessian matrisinin yaklaşık değerini kullanır. Levenberg Marquardt algoritması için Hessian matrisinin yaklaşık değeri şu şekilde hesaplanabilir (Dursun 2009);

$$H(n) = J^T(n)J(n) + \alpha I \quad (3.21)$$

Denklem 3.21'de J matrisi Jakobien matrisi olarak adlandırılır ve ağ hatalarının ağırlıklara göre birinci türevinden oluşmaktadır;

$$J(n) = \frac{\partial e(n)}{\partial w(n-1)} \quad (3.22)$$

Denklem 3.22'de e , ağ hataları vektörüdür. Jakobien matrisi, hesaplamada Hessian matrisinden kolay olduğu için tercih edilmektedir. Ağ gradyeni,

$$g(n) = J^T(n)e(n) \quad (3.23)$$

olarak hesaplanır ve ağırlıklar Denklem 3.23'ya göre değiştirilir;

$$w(n+1) = w(n) - [H(n)]^{-1}g(n) \quad (3.24)$$

Marquardt parametresi, μ , skaler bir sayıdır. Eğer μ sıfırsa, bu yöntem Newton algoritması, eğer μ büyük bir sayı ise, küçük adımlı gradyen azalması yöntemi haline gelir. Newton yöntemleri, en küçük hata hesaplamalarında daha hızlı ve kesin sonuçlar vermektedir. Her performans fonksiyonu azalmasında μ azaltılır ve sadece deneme niteliğindeki bir adım performans fonksiyonunu yükseltecekse μ arttırılır. Bu yöntemle, algoritmanın her iterasyonunda, performans fonksiyonu sürekli azaltılır (Dursun 2009).

Genel olarak Levenberg- Marquardt algoritması yavaş yakınsama problemlerinden etkilenmez. Yöntemdeki hedef, performans fonksiyonunu en küçük yapacak ağırlık değerini bulmaktır (Dursun 2009).

Yapay sinir ağı katman sayılarına göre ise, tek katmanlı ve çok katmanlı olmak üzere ikiye ayrılmaktadır. Tek katmanlı yapay sinir ağı, sadece girdi ve çıktı katmanlarından oluşmakta iken çok katmanlı yapay sinir ağı birçok nöronun birbirine bağlanması ile meydana gelen birkaç katmandan oluşmaktadır. Tek katmanlı ağlarda her ağı bir ya da daha fazla girdisi ve yalnızca bir çıktısı bulunmakta iken çok katmanlı ağlarda, girdi katmanı, çıktı katmanı ve bu iki katman arasında da bir veya birden fazla gizli katman bulunmaktadır. Eğriselliği sağlayacak gizli tabakanın bulunmaması sebebiyle tek katmanlı ağlar daha çok doğrusal problemler için kullanılmaktadır. Çok katmanlı ağlar ise karmaşık problemlerin çözümünde özellikle de sınıflandırma, tanıma ve tahminlerde kullanılmaktadır dolayısıyla çok katmanlı ağlar doğrusal olmayan problemlerin çözümünde başarılı sonuçlar elde etmektedir.

Yapay sinir ağlarının yapısını, ağda bulunan katman sayıları, bu katmanların kaç adet nörondan oluşacağı, nöronların birbirlerine göre konumu ve nöronlar arası sinyallerin akış yönleri belirlemektedir. Yapay sinir ağı yapıları arasında performans ve karakteristik özellikleri bakımından farklılıklar bulunmaktadır. Yapay sinir ağının tasarımı aşamasında bu ağ yapıları arasından uygulamaya en elverişli olanı seçilir. Yapay sinir ağı kurulumu aşamasında örnek veri seti, ağ eğitimi ve test işlemleri için iki ayrı veri setine ayrılır. Veri tipi, veri miktarı ve problem karakteristiği veri setini ayırma işleminde önemli etkenlerdir. Eğitim ve test veri seti seçiminde yanlışlık yapılması ağ performansını etkilemektedir. Yapay sinir ağı modeli oluşturulurken, ağ yapısının ve yapı özelliklerinin belirlenmesi, nörondaki fonksiyonların özelliklerinin belirlenmesi ve öğrenme algoritmasının seçilerek parametrelerinin belirlenmesi aşamaları dikkatle ve uygulanacak problemin özelliğine göre yapılır.


3.2.2.2. k-Kat çapraz doğrulama algoritması

k-Kat çapraz doğrulama algoritmaları ile örnekler k tane rastgele alt örneklere bölünürler. Bölünen k tane rastgele alt örnek, modelin doğrulanması aşamasında, k-1 tane alt örnek ise eğitim aşamasında kullanılır. Çapraz doğrulama algoritması ile, doğrulama işlemi k kere tekrarlanmaktadır. Her alt örnek, doğrulama sırasında bir kere kullanılır. Sonuç üretmek amacıyla k sonuçlarının ortalaması alınabilmektedir. Yöntem, rastgele tekrarlanan alt örnekleme üzerinden elde edilen gruplarda eğitim ve test için kullanılabilir (Akşahin 2010). Çalışmada, veriler 3'lü ve 5'li setler halinde rastgele olarak seçilerek sınıflandırılmıştır.


3.2.2.3. Destek vektör makineleri

Destek vektör makineleri istatistiksel öğrenme teorisine dayalı parametrik olmayan bir sınıflandırma yöntemidir. Temel olarak iki sınıfa ait verileri birbirinden en uygun şekilde ayırmak için kullanılır ve bu yöntem kullanılarak az sayıda veri ile doğru sınıflandırma sonuçları elde etmek mümkündür. Sınıflandırma için iki grup arasında bir sınır çizilerek iki grup birbirinden ayrılır. Burada, Destek Vektör Makineleri sınırın çizileceği yeri belirlemektedir. Bu işlem için iki gruba da yakın ve birbirine paralel iki sınır çizgisi çizilir ve bu sınır çizgileri birbirlerine yaklaştırılarak ortak sınır çizgisi üretilir (Şeker 2008). Destek Vektör Makineleri ile sınıflandırma sürecinde iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu ile birbirinden ayrılması amaçlanmaktadır. Karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiper-düzlem bulunur. Şekil 3.24'de görüldüğü gibi iki sınıflı verileri

birbirinden ayırabilen birçok hiper düzlem çizilebilir. Ancak destek vektör makinelerinin amacı kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkararak en uygun ayrımı yapan düzleme optimum hiper düzlem ve sınır genişliğini sınırlandıran noktalar ise destek vektörleri olarak adlandırılmaktadır. Özetle Destek Vektör Makinelerinde amaç, farklı sınıflara ait destek vektörleri arasındaki uzaklığı maksimize etmektir. Destek vektör makineleri verilerin doğrusal ayrılıp ayrılamama durumuna göre ikiye ayrılır. Doğrusal olarak ayrılabilen verileri arasında maksimum uzaklığın bulunması işlemi kolaydır ancak doğrusal olarak ayrılmayan veriler üzerinde sınıflandırma yaparken, öncelikle veriler doğrusal olarak ayrılacakları bir uzaya aktarılmalıdırlar. Destek vektör makineleri, el yazısı tanıma, yüz tanıma, ses tanıma, konuşmacı tanıma, metin sınıflandırma gibi alanlarda uygulanabilmektedir (Kavzaoğlu ve Çölkesen 2010).



Şekil 3.24. İki sınıflı bir problem için hiper düzlemler (Kavzaoğlu ve Çölkesen 2010)



Şekil 3.25. Optimum hiper düzlem ve destek vektörleri (Kavzaoğlu ve Çölkesen 2010)

3.2.2.4. k-En yakın komşuluk yöntemi

k-En Yakın Komşuluk yöntemi basitliği sebebiyle en çok tercih edilen makine öğrenmesi ve sınıflandırma yöntemlerinden biridir. k faktörüne göre örnek veri noktasının bulunduğu sınıfın ve en yakın komşunun belirlendiği bir sınıflandırma yöntemidir. Bu yöntemde sınıflandırma, karşılaştırma yapılacak olan örnek, eğitim setinde bulunan örnekler ile arasındaki benzerliğe göre yapılmaktadır. k-NN yönteminde, eğitim setinde yer alan örnekler n boyutlu sayısal nitelikler ile belirtilir. N boyutlu uzayda her örnek bir noktayı temsil edecek şekilde bulunur. Bu durumda tüm örnekler n boyutlu örnek uzayında tutulmaktadır. Bilinmeyen bir örnek ile karşılaşıldığında, eğitim setinden ilgili örneğe en yakın k tane örnek belirlenir ve yeni örneğe, en yakın komşusunun katsayısı atanır. k-NN yönteminin performansında en önemli ve etkili parametreler uzaklık ölçütü, (k) komşu sayısı ve ağırlıklandırma yöntemidir. Ayrıca performansta önemli bir diğer nokta ise örnekler arası yakınlığın ölçümüdür. Ölçüm, Öklid ya da başka bir uzaklık ölçütü kullanılarak yapılabilir. Yöntem basit ve az sayıda parametre gerektiren bir yapıya sahiptir. k-NN yönteminde, komşu sayısı (k) parametresinin değerine dayalı olarak sınıflandırma yapılır. Sınıflandırma sürecinde k=1 için, en yakın komşunun bulunduğu sınıfa atanırken, k sayısı örnek sayısına (N) yaklaştıkça veri setinde yer alan tüm veriler dikkate alınarak oylamaya göre seçim yapılmaktadır (Zengin 2017).

k-En Yakın Komşuluk yönteminde ilk adım öğrenme sürecidir. Bu süreçte öznitelik vektörleri çıkarılmış olan veri, sınıflandırma sistemine öğretilir ve hangi sınıfa ait olduğu belirtilir. Daha sonra test verisinin öğrenme verilerine olan uzaklık metrikleri hesaplanarak test aşamasına geçilir. Uzaklık metrikleri hesaplandıktan sonra sonuçlar artan şekilde sıralanır. Test verisinin ait olduğu sınıf tespiti k tane en yakın komşudan en fazla üye sayısının olduğu sınıf seçilerek yapılmaktadır (Yazgaç 2016).

3.2.3. Otomobil seslerinin sınıflandırılmasında kullanılan yöntemler

Bu çalışmada, otomobil motorlarından elde edilen sinyallerde araçları birbirlerinden ayırabilecek derecede pik noktaları olduğu görülmüş bu nedenle sinyallerin işlenmesinden önce ön filtreleme işlemine gerek duyulmamıştır. Alınan sinyallerde zaman ve frekans bölgesi analizleri yapılmıştır. Sinyallere welch yöntemi uygulanarak güç spektrum yoğunlukları (PSD) elde edilmiş ve çizdirilmiştir. Sinyallerin hangi frekans bandında farklılıklar verdiği incelenmiştir. 5 araç içinde farklı frekans bölgeleri belirlenmiştir. Sinyal işleme yöntemleri kullanılarak farklı öznitelikler elde edilmiştir. Öznitelik çıkarma ses tanımlama ve sesin önemli özniteliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Elde edilen öznitelikler sonucunda çeşitli yapay sinir ağı yöntemleri, destek vektör makineleri yöntemleri ve k-en yakın komşuluk yöntemleri kullanılarak sınıflandırma yapılmıştır.

Tez çalışmasında ilk olarak güç spektrum yoğunlukları welch yöntemi kullanılarak elde edilmiştir. Spektrum analizi bir sinyalin frekans içeriği hakkında bilgi vermektedir. Sinyallerin frekans bilgileri bazı durumlarda zaman bölgesi çözümünden daha yararlı açılımlar sağlamaktadır. Genel olarak spektrum yaklaşım yöntemleri iki grupta incelenir. Bu gruptan ilki içinde Welch yönteminde bulunduğu, spektral yaklaşım veya parametrik olmayan yaklaşımdır ve spektrumun tamamının şekli ile ilgilenir. Diğer grup ise parametrik olan gruptur ve spektrumun tamamı yanısıra yerel

özelliklerini de dikkate alır. Güç spektrum yoğunluğu (PSD)'nin en basit şekli periodogram ile ifade edilir (Dursun 2009). Welch yöntemi ise periodogram yönteminin iyileştirilmiş hali olan bir yöntemdir.

Welch yönteminde sinyaller, üst üste çıkışabilecek bölümlere ayrılırlar. Her bölümün iyileştirilmiş periodogramı alınıp daha sonra bu periodogramların ortalaması bulunmaktadır. Welch yöntemi güç spektral yoğunluğunu, iyileştirilmiş periodogramların ortalamasını alarak hesaplamaktadır. İyileştirilmiş periodogram denklemi, Denklem 3.25'de verilmiştir (Koçak vd. 2016).

$$S_{xx}(f) = \frac{T_s}{KM} \left| \sum_{n=0}^{M-1} x_i(n)w(n).e^{-j2\pi fn} \right|^2 \quad (3.25)$$

Burada; $f=f_s$ normalize edilmiş frekans değişkenidir. Ölçekleme faktörü T_s ayrık zaman işaret spektrumunun genliğini analog işaret spektrumuna eşit olmasını sağlar. Bu son eşitlikte $w(n)$ pencereleme fonksiyonu ve K normalize sabiti olup Denklem 3.26'da verilmiştir (Koçak vd. 2016).

$$K = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (3.26)$$

Sonuç olarak güç spektral yoğunluğu kestirimi Denklem 3.27'deki hali almaktadır (Koçak vd. 2016).

$$P_{Welch}(f) = \frac{1}{L} \sum_{i=0}^{L-1} S_{xx}(f) \quad (3.27)$$

Burada L zaman dizisi serisi uzunluğunu oluşturmaktadır. Özellikle sinyal gürültü oranı düşükse periodograma göre daha iyi bir çözünürlük elde etmek amacıyla Welch yöntemi kullanılabilir (Koçak vd. 2016).

Güç spektrumu otokorelasyon fonksiyonunun Fourier dönüşümü olarak tanımlanabilir. Sonlu enerjisi olmayan dolayısıyla Fourier dönüşümü alınmayan sinyaller bir ortalama güce sahiptir ve güç spektral yoğunluğu ile karakterize edilirler (Dursun 2009; Proakis ve Manolakis 2010). Frekans analizi yapılacak olan sinyallerin tamamı sonlu sayıda örnek içermektedir. Dolayısıyla Fourier dönüşümü, sonsuz ve sürekli sinyaller için uygulandığından kullanılmamaktadır. Bu nedenle sonlu uzunluktaki bir sinyalin Fourier katsayılarını veren Ayrık Fourier Dönüşümü (DFT) kullanılmaktadır. Ayrık Fourier dönüşümü, ayrık zamanlı sinyal işleme, algoritma ve sistemlerin analizi, tasarımı, doğrusal filtreleme, spektrum analizi gibi sinyal işleme uygulamalarında önemli bir yere sahiptir. Ayrık ve sonsuz uzunluktaki bir $x[n]$ dizisinin ayrık zamanlı fourier dönüşümü aynı şekilde $x(\omega)$ ile ifade edilir. Denklem 3.28, sonsuz uzunluktaki bir sinyalin ayrık zamanlı Fourier dönüşümünü ifade etmektedir (Oppenheim vd. 1997; Rangayyan 2002; Akşahin 2010).

$$X(\omega) = \sum_{n=-\infty}^{\infty} x[n]e^{-j\omega n} \quad (3.28)$$

Sonlu sayıdaki bir sinyalin uzunluğu N olduğu takdirde ω , Denklem 3.29'deki gibi tanımlanmaktadır (Oppenheim vd. 1997; Rangayyan 2002; Akşahin 2010).

$$\omega = (2\pi/N)k \quad (3.29)$$

Burada k pozitif bir tam sayıyı ifade eder. Sonlu sayıdaki ayrık bir sinyalin, Ayrık Fourier Dönüşümü, Denklem 3.30'de gösterilmektedir (Oppenheim vd. 1997; Rangayyan 2002; Akşahin 2010).


$$X(k) = \sum_{n=0}^{N-1} x[n]e^{-j2\pi kn/N}; k = 0, 1, \dots, N-1 \quad (3.30)$$

Benzer şekilde frekans uzayı katsayılarını zaman uzayına taşıyan Ters Ayrık Fourier Dönüşümünün denklemi, Denklem 3.31'deki gibi yazılmaktadır (Oppenheim vd. 1997; Rangayyan 2002; Akşahin 2010).


$$x[n] = \frac{1}{N} \sum_{k=0}^{N-1} X(k)e^{j2\pi kn/N}; n = 0, 1, \dots, N-1 \quad (3.31)$$

4. BULGULAR VE TARTIŞMA


Bu çalışmada 5 adet farklı araç motorundan alınan ses verileri incelenmiştir. Her araçtan 50 adet ve ortalama 10'ar saniyelik sürelerle ses kayıtları alınmıştır. Ses şiddetlerinin farklılıkları, analiz sonucunu etkilememesi için tüm sinyaller 1'e normalize edilmiştir. Tüm ses kayıtlarındaki 10 saniyeyi aşan süreler kırılarak, tüm kayıtlar net 10 sn olacak şekilde ayarlanmıştır. Aşağıdaki şekillerde 5 araç için, her araçtan alınmış olan 50 adet ses kayıt örneğinden, 1 adet 10'ar saniyelik ses kayıt örnekleri gösterilmiştir.



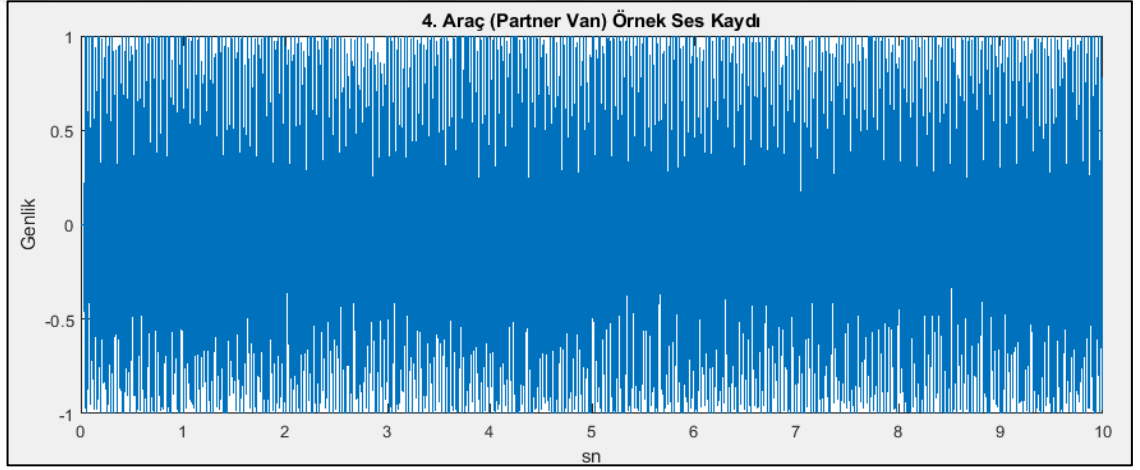
Şekil 4.1. Renault Symbol (1.araç) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği




Şekil 4.2. Renault Fluence (2.araç) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği



Şekil 4.3. Peugeot 207 (3.aracı) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği




Şekil 4.4. Partner Van (4.aracı) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği




Şekil 4.5. Opel Zafira (5.aracı) 50 adet ses kaydı arasından alınmış 1 adet 10 sn'lik ses kayıt örneği


Araçlara ait 50'şer adet ses kayıtları incelenmiş olup grafikleri çizdirilmiştir. Bu ses verilerinden, Welch yöntemi kullanılarak Güç Spektrum Yoğunlukları (PSD) hesaplanmıştır. Her araç için güç spektrum yoğunluğu grafikleri çizdirilmiştir. Ancak 1 araçta toplam 50 adet ses kaydı olup, her ses kaydına ait ayrı güç spektrum genliği grafiği bulunduğu için, örnek olarak 5 adet aracın 50 ses kaydından yalnızca 1 adet ses kaydına ait güç spektrum yoğunluk grafikleri aşağıdaki şekillerde gösterilmiştir.




Şekil 4.6. Renault Symbol (1.araç) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği




Şekil 4.7. Renault Fluence (2.araç) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği



Şekil 4.8. Peugeot 207 (3.aracı) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği



Şekil 4.9. Partner Van (4.aracı) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği



Şekil 4.10. Opel Zafira (5.aruç) 50 adet ses kaydı arasından alınmış 1 adet ses kayıt örneğinin PSD grafiği


Güç spektrum yoğunluğu (PSD) grafikleri çizdirildikten sonra her grafik ayrı ayrı incelenmiştir. PSD grafiklerinden 17 adet farklı frekans bölgesi seçilmiştir. Seçilen 17 adet frekans bölgesinin güç spektrum genlik değerleri her araç için öz nitelik olarak alınmıştır. Her araçtan 50 adet ses kaydı olduğu için bu ses kayıtlarının 17 adet frekans bölgesindeki değerleri tek tek alınıp toplamda her araç için 17x50'lik öz nitelik matrisi oluşturulmuştur. Aşağıdaki Çizelge 4.1'de, f_1 - f_{17} frekans bölgeleri verilmiştir.

Çizelge 4.1. 17 adet öz nitelik ve bu öz niteliklerin tespit edildiği frekans değerleri

17 Adet Farklı Bölgelerden Alınmış Öz nitelikler	Frekans Değerleri
f_1	26 Hz
f_2	27 Hz
f_3	28-32 Hz (Bu aralıktaki maksimum genlik değeri alınmıştır.)
f_4	51-52 Hz (Bu aralıktaki maksimum genlik değeri alınmıştır.)
f_5	54 Hz
f_6	55 Hz
f_7	59-61 Hz (Bu aralıktaki maksimum genlik değeri alınmıştır.)
f_8	76-77 Hz (Bu aralıktaki maksimum genlik değeri alınmıştır.)
f_9	80 Hz
f_{10}	85 Hz
f_{11}	107 Hz
f_{12}	113 Hz
f_{13}	133 Hz
f_{14}	230-235 Hz (Bu aralıktaki maksimum genlik değeri alınmıştır.)
f_{15}	266-273 Hz (Bu aralıktaki maksimum genlik değeri alınmıştır.)
f_{16}	320 Hz
f_{17}	411-425 Hz (Bu aralıktaki maksimum genlik değeri alınmıştır.)

Şekil 4.11’de belirlenen 17 adet frekans bölgesinden biri için seçilen öz nitelik değeri örnek olarak gösterilmiştir. Şekil 4.11’e bakılacak olursa, 1. araç için 50 adet ses kaydı arasından yalnızca 1 adet ses kaydına ait güç spektrum yoğunluğu grafiği görülmektedir. Grafik üzerinde görülen X: 80.08 değeri, çizdirilen grafiğin ait olduğu ses kaydı içinden belirlenmiş olan 17 adet farklı frekans değerinden sadece biri olan 80 Hz’lik frekans değerini göstermektedir. Y: 0.01027 değeri ise, 80 Hz’lik frekans değerine karşılık gelen genlik yani öz nitelik değerini göstermektedir. Bu durumda Renault Symbol (1. Araç) için öz nitelik değerlerinden birisi Y: 0.01027 değeridir. Bu değeri yukarıya yuvarlayacak olursak Y: 0.0103 genlik değeri öz nitelik olarak alınabilir. Yukarıda anlatılanlardan da anlaşılacağı üzere bir araca ait 50 farklı ses kaydından, her bir ses kaydına ait 17 farklı frekans bölgesinden çekilen genlik değerleri öz nitelikleri

oluşturmaktadır. Aşağıdaki Şekil 4.12’de Renault Symbol (1.Araç) aracına ait, 50 adet ses kaydının öznelik değerleri ekran görüntüsünün sayfaya sığmaması nedeniyle verilemediği için küçültülerek 12 adet ses kaydına ait ve her ses kaydından seçilen 17 farklı öznelik değeri örnek olarak verilmiştir.

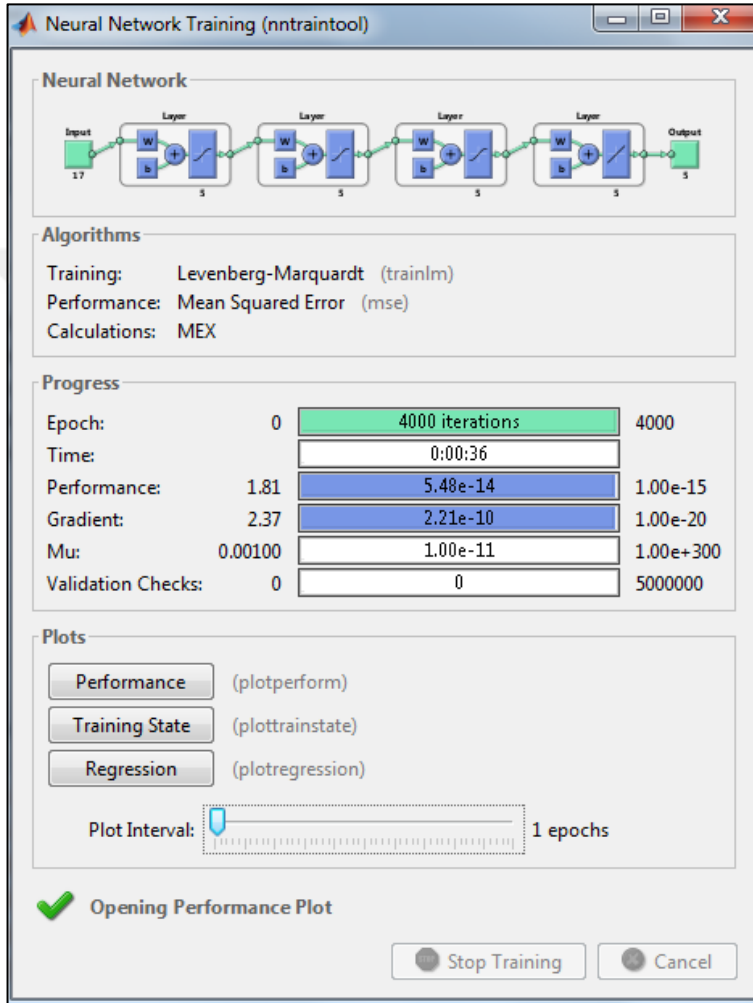


Şekil 4.11. Renault Symbol (1.arac) aracına ait 1 adet öznelik değeri


	1	2	3	4	5	6	7	8	9	10	11	12
1	4.4358e-05	4.2355e-05	5.9048e-05	5.4892e-05	5.3862e-05	5.5566e-05	3.8844e-05	6.2252e-05	4.1667e-05	4.1404e-05	4.0450e-05	3.5706e-05
2	0.0157	0.0155	0.0164	0.0166	0.0172	0.0151	0.0164	0.0176	0.0171	0.0160	0.0130	0.0156
3	7.8526e-04	8.3348e-04	8.1399e-04	7.7894e-04	8.3339e-04	7.7039e-04	7.4553e-04	9.0114e-04	8.7596e-04	8.6598e-04	5.9213e-04	7.8377e-04
4	5.6156e-05	2.4090e-05	1.2744e-05	7.8630e-05	6.0373e-05	2.8419e-05	1.0973e-04	7.7111e-05	4.5031e-05	7.3091e-05	6.5118e-05	2.4268e-05
5	0.0212	0.0212	0.0209	0.0210	0.0222	0.0208	0.0205	0.0214	0.0226	0.0224	0.0186	0.0213
6	2.0281e-05	3.1311e-05	1.3328e-05	9.6216e-05	6.6613e-05	6.2168e-05	2.0167e-05	4.6826e-05	2.5785e-05	2.4620e-05	9.2946e-06	1.5566e-05
7	3.9719e-05	3.0364e-05	3.2319e-05	7.1483e-05	4.6463e-05	6.4045e-05	7.2352e-05	9.1754e-05	4.8816e-05	8.9883e-05	1.9922e-04	6.6661e-05
8	1.9030e-04	3.7472e-05	1.6123e-05	1.5601e-05	2.0099e-05	8.9838e-05	2.4859e-05	3.7890e-05	2.9961e-04	2.7685e-05	1.0255e-04	5.3952e-05
9	0.0103	0.0107	0.0102	0.0109	0.0113	0.0118	0.0115	0.0118	0.0116	0.0117	0.0116	0.0130
10	2.2502e-05	1.9751e-05	1.1900e-05	8.8749e-06	1.2112e-05	1.5650e-05	9.5802e-06	2.0332e-05	1.7736e-05	1.8075e-05	1.8778e-05	2.2902e-05
11	0.0230	0.0233	0.0237	0.0250	0.0261	0.0244	0.0249	0.0258	0.0261	0.0250	0.0195	0.0248
12	4.1818e-05	2.7133e-05	3.0216e-05	2.5254e-05	4.9547e-05	4.5140e-05	2.8740e-05	3.9959e-05	2.8050e-05	2.8060e-05	9.5411e-05	3.1546e-05
13	5.2872e-04	3.9109e-04	5.0402e-04	5.1685e-04	5.0902e-04	2.9050e-04	3.3202e-04	4.4565e-04	6.5617e-04	5.3203e-04	5.7988e-04	9.2064e-04
14	8.6223e-06	1.7624e-05	1.6335e-05	8.3592e-06	1.5605e-05	1.2954e-05	2.3047e-05	1.6564e-05	1.2661e-05	8.8428e-06	1.1313e-05	7.2866e-06
15	5.7699e-04	7.7430e-04	7.5038e-04	7.9225e-04	9.2375e-04	6.7604e-04	8.5126e-04	8.2885e-04	6.7426e-04	9.5169e-04	8.1543e-04	9.8862e-04
16	3.2928e-04	2.5645e-04	1.6163e-04	1.6727e-04	2.3619e-04	2.7323e-04	2.0978e-04	3.3046e-04	2.8567e-04	4.2710e-04	2.6358e-04	3.0555e-04
17	7.2811e-05	3.5181e-05	4.7075e-05	3.6999e-05	3.4656e-05	2.8816e-05	1.7700e-05	1.7352e-05	2.1180e-05	5.0870e-05	7.2047e-05	5.1108e-05

Şekil 4.12. Renault Symbol aracına ait 12 adet ses kaydının 17 farklı öznelik değerleri


Her araç için ayrı ayrı oluşturulan 17x50'lik öznitelik matrisindeki öznitelikler çekildikten sonra bu verilerden 17x25'lik kısmı eğitim aşamasında geriye kalan 17x25'lik veri kısmı ise test aşamasında kullanılmıştır. Sınıflandırma aşamasında ilk olarak ileri beslemeli yapay sinir ağları kullanılmıştır. Yapay sinir ağları farklı nöron sayıları ve farklı gizli katman sayılarında denenmiştir. Denemesi yapılan yapay sinir ağlarından, Levenberg-Marquardt algoritması kullanılarak 17 adet giriş verisinde 4 gizli katman sayısında ve çıkış katmanında 5 nöron içeren örnek bir yapay sinir ağının eğitimi Şekil 4.13 ve Şekil 4.14'de verilmiştir.



Şekil 4.13. Yapay sinir ağı eğitim aşaması



Şekil 4.14. Yapay sinir ağında kullanılan giriş veri sayısı, gizli katman sayısı ve çıkış verisindeki nöron sayısı



Şekil 4.15. Yapay sinir ağı eğitim performans eğrisi

Şekil 4.15 ise yapay sinir ağının eğitiminde istenen performans eğrisini göstermektedir. Yapay sinir ağının iyi eğitilip eğitilmediği bu grafikten gözlemlenebilir. Çalışmada ortalama hata karesi düzeyi 10^{-15} olacak şekilde yapay sinir ağı eğitilmiştir. Eğri, 10^{-15} ’lik düzeye ne kadar yaklaşırsa eğitim oranının o oranda başarı göstereceği beklenir ve dolayısıyla iyi eğitim sonucunda test işleminde o oranda başarılı bir şekilde sınıflandırma yapacağı beklenmektedir.

Yapay sinir ağı eğitildikten sonra test edilmiş ve çıkış verileri incelenmiştir. Eğitim setinin çıkış verileri 1 ve 0 tanımlaması yapacak şekilde eğitilmiştir. Tanıma işlemi şu şekilde anlamlandırılmaktadır; Her araç için bir satır bulunmaktadır. İlk satır 1. araç için, ikinci satır 2. araç, üçüncü satır 3. araç, dördüncü satır 4. araç ve beşinci satır ise 5. aracı temsil etmektedir. Daha önce de bahsedildiği gibi test 25 veri ile yapılmıştır. Her araç için 25 adet test verisi, 5 araç için toplamda 125 adet test verisi bulunmaktadır. Test aşamasından sonra çıkış verisinde, 1. araç için 0-25 arasındaki sütun incelenir ve 1. satırda 1 veya 1’e yakın değer ne kadar bulunduğu 1. aracın o kadar tanındığı anlamını taşır ve oranlanarak tanıma yüzdesi hesaplanabilir. Aynı şekilde 2. araç için 25-50 aralığındaki sütun incelenir ve 2. satırdaki 1 ve 1’e yakın değerlerin sıklığına bakılarak tanıma oranı hesaplanır. Bu işlem 5 araç için, her araç kendi satırında olmak üzere yapılmıştır. İleri beslemeli yapay sinir ağı kullanılarak yapılan sınıflandırma çalışmasında, her katmanda 5 nöron bulunan 4 gizli katmanla yapılan test sonucunda % 99.2 başarı oranında sınıflandırma yapılmıştır.

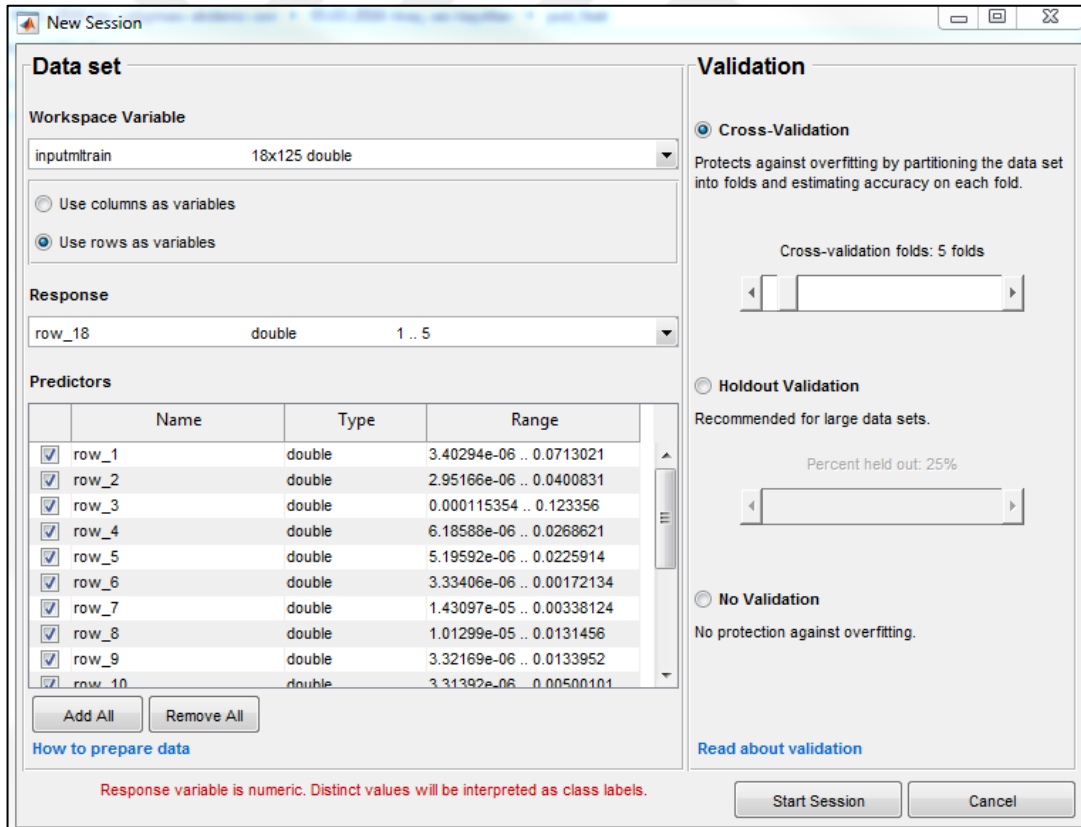
Sınıflandırma çalışması, diğer sınıflandırma yöntemlerinden Destek Vektör Makineleri (SVM) ve k- En Yakın Komşuluk (k-NN) yöntemleri ile de ayrıca yapılmıştır. Bu sınıflandırma yöntemleri, MATLAB programında uygulamalar kısmında bulunan Makine öğrenmesi araç kutusu kullanılarak yapılmıştır. Şekil 4.16’da

MATLAB programında diğer sınıflandırma yöntemlerinin bulunduğu araç kutusu gösterilmiştir.



Şekil 4.16. MATLAB programındaki sınıflandırma yöntemlerinin bulunduğu araç kutusu

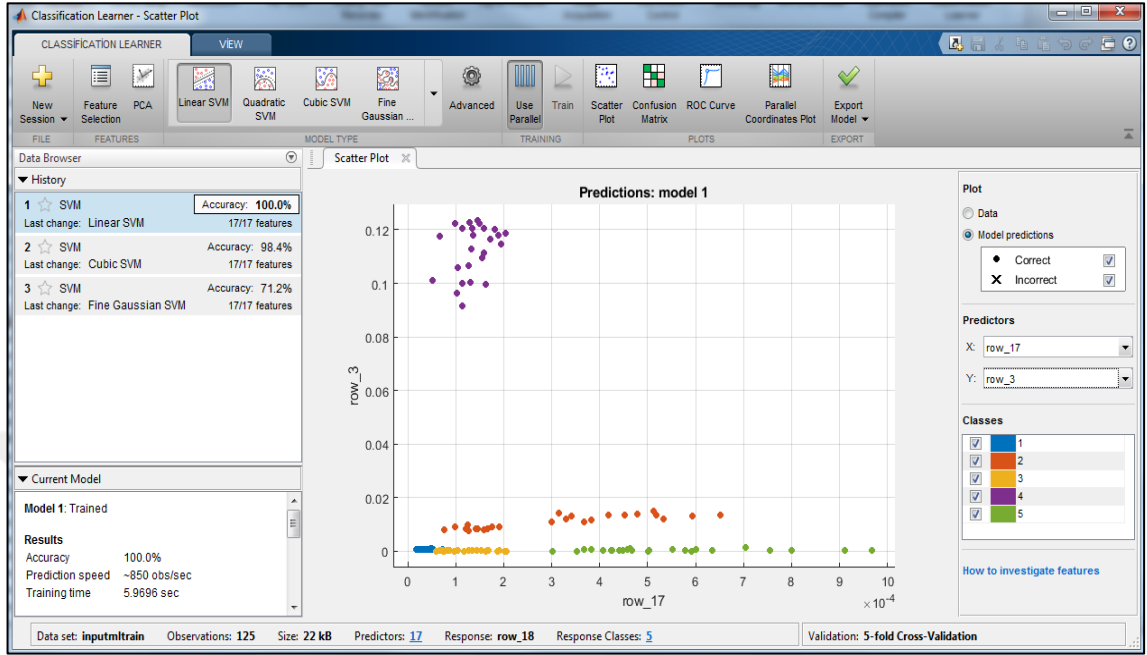
Destek Vektör Makineleri yöntemi MATLAB programının uygulamalar penceresi kullanılarak açılmıştır. İlk olarak eğitim için oluşturulan 17x125'lik öznelik matrisi, veri setine girdi olarak verilmiştir. 18. satır ise sınıflandırma aşamasında 1-5 aralığındaki araçların ayrımı için kullanılmaktadır. Eğitim aşamasında, 5-kat çapraz doğrulama ve 3-kat çapraz doğrulama seçilerek veriler, 5'li setler halinde ve 3'lü setler halinde rastgele eğitilmiştir. Şekil 4.17'de Eğitim aşamasındaki veri seti gösterilmiştir.




Şekil 4.17. Destek vektör makineleri yönteminde eğitim seti

Destek Vektör Makineleri yönteminde Lineer, Cubic ve Fine Gaussian yöntemleri karşılaştırılmıştır. Lineer SVM'de 5-kat çapraz doğrulamada, %100 doğruluk oranında eğitim gerçekleştirilmiştir. Bu nedenle eğitim aşamasında Lineer SVM

yöntemi kullanılmıştır. Şekil 4.18’de farklı SVM yöntemlerinin eğitim aşamasındaki doğruluk oranları verilmiştir. Şekil 4.19’da öznelik matrisinin dağılımı gösterilmektedir.



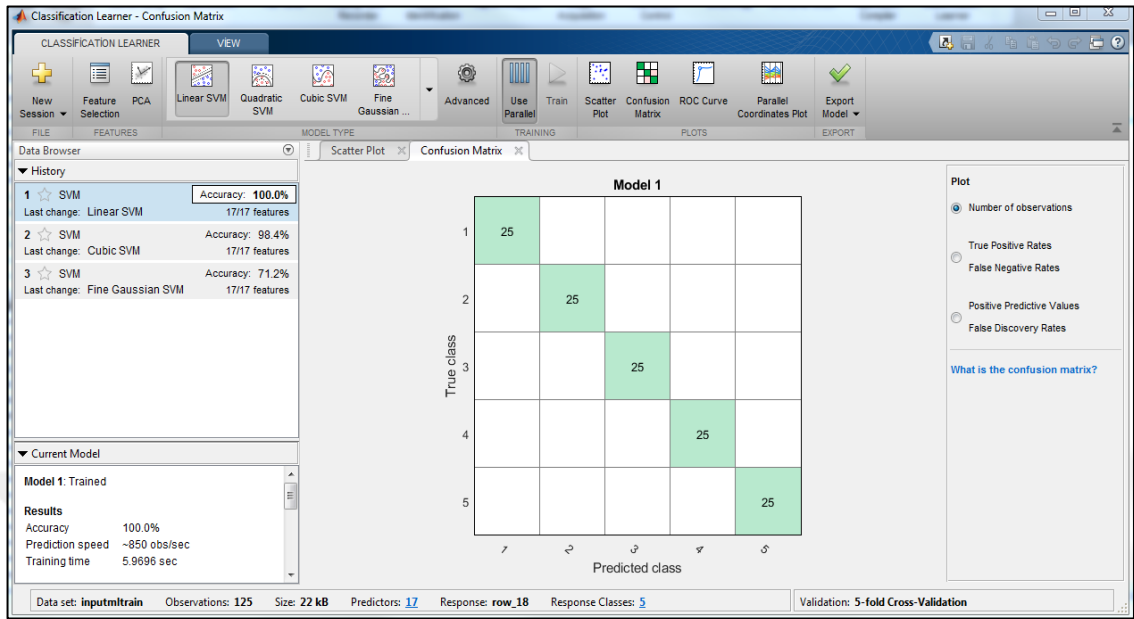
Şekil 4.18. Farklı SVM yöntemlerinde eğitim doğruluk oranları



Şekil 4.19. Öznelik matrisinin dağılım grafiği

Şekil 4.19’den de görüldüğü üzere tüm öznelikler ayrıştırılabildiği görülmektedir. Şekilde 5 farklı renk ile tanımlanan 1., 2., 3., 4., ve 5. araçlar rahatlıkla görülebilmektedir. Eğitim aşamasının nasıl tamamlandığını ayrıca gösteren hata matrisi Şekil 4.20’de verilmiştir.

Şekilden 4.20'den de anlaşılacağı üzere, 25 adet eğitim verisi her araç için ayrıştırılabilmektedir.

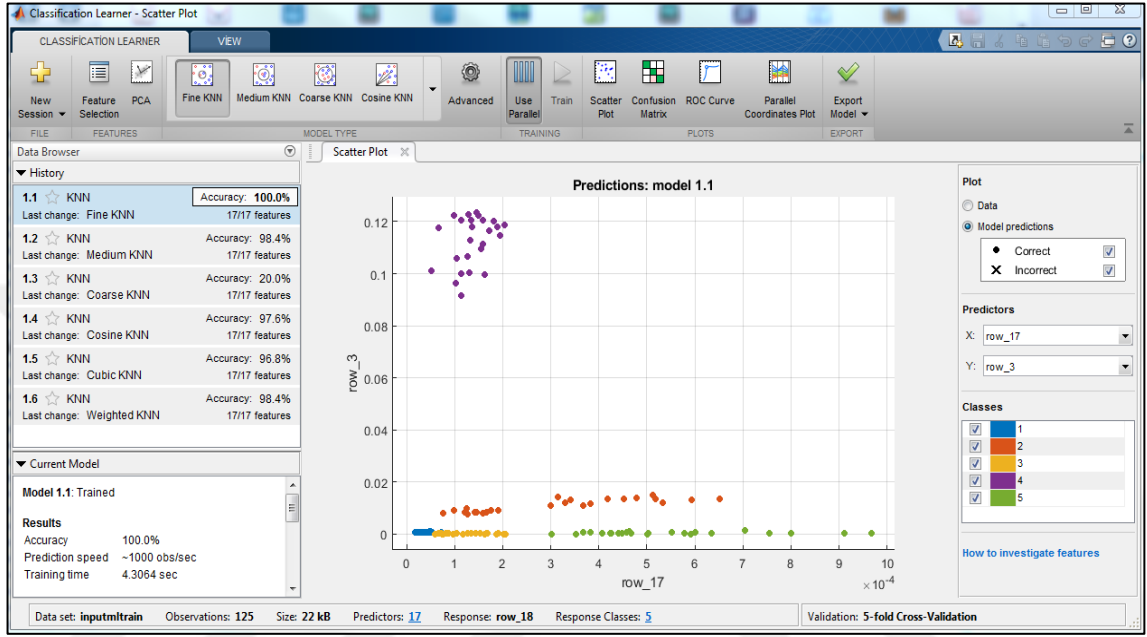


Şekil 4.20. SVM yönteminde eğitim aşamasını gösteren hata matrisi

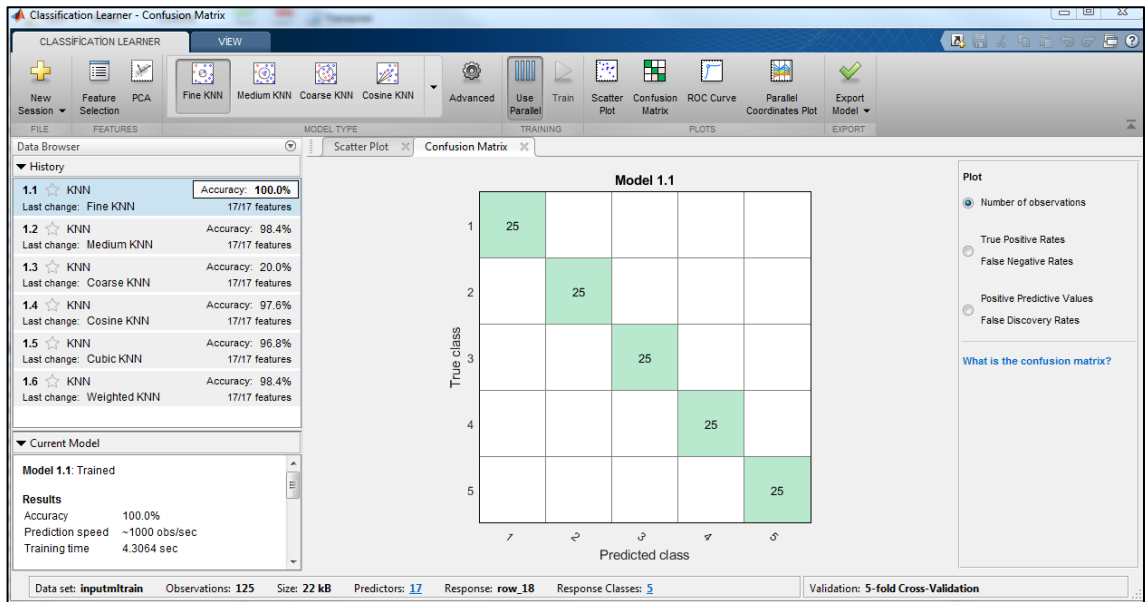
Destek vektör makineleri yönteminde test aşamasına gelindiğinde ilk olarak testte kullanılacak olan 1 araç için 17x25, 5 araç için toplamda 17x125 olan öznelik matrisi komut satırına gönderilir. Daha sonra Destek Vektör Makineleri yöntemi için sınıflandırma kodu `yfit = SVM.predictFcn(X)` komut satırına yazılarak sınıflandırma sonuçları incelenmiştir. Araçların tanıma oranları şu şekilde anlamlandırılabilir; Daha önce de bahsedildiği üzere eğitim aşamasındaki 18. satır araçların tanınması için numaralandırılma yapılan satırdır. 1. aracın tanıma oranı ilk 25 adetlik test verisinde kaç kere 1 rakamının bulunduğu ile, 2. aracın tanıma oranı ikinci 25 adetlik test verisinde kaç kere 2 rakamının bulunduğu 3. aracın tanıma oranı üçüncü 25 adetlik test verisinde kaç kere 3 rakamının bulunduğu, 4. ve 5. araçlarında aynı şekilde takip eden 25 adetlik test verilerinde kaç kere 4 ve 5 rakamlarının bulunduğu ile doğru orantılıdır. Destek Vektör makineleri yöntemi ile araçlar hem eğitim aşamasında hem de test aşamasında %100 başarı oranında ayrıştırılarak sınıflandırılmıştır.

Diğer sınıflandırma yöntemlerinden ise, k-En Yakın Komşuluk Yöntemi kullanılmıştır. Farklı k değerlerinde yöntem ayrı ayrı incelenmiştir. Şekil 7.21'de farklı k değerlerinde uygulanan yöntemlerden elde edilen eğitim başarı oranları görülmektedir. Şekilden görüleceği üzere k=3 değerinde Fine KNN yöntemi ile eğitim başarı oranı %100 olarak bulunmuştur. Test kısmı daha önce Destek vektör makineleri yönteminde bahsedildiği gibi toplamda 125 adet test verisinin her araç için 25'er adet test verisine ayrılmasıyla oluşmaktadır. İlk 25 test verisi 1. araç, 25-50 aralığındaki test verisi 2. araç, 50-75 aralığındaki test verisi 3. araç, 75-100 aralığındaki test verisi 4. araç ve 100-125 aralığındaki test verisi 5. araç için kullanılmaktadır. Test aşamasına geçildiğinde, k-En Yakın Komşuluk yöntemi için sınıflandırma kodu `yfit=Fineknn.predictFcn(X)` komut satırına yazılarak sınıflandırma sonuçları incelenmiştir. Yöntem 1., 2., 3. ve 4. araçları doğru şekilde sınıflandırırken 5. aracın 1

verisi 4. araç olarak tanımlanmıştır. Bu nedenle toplamda 125 adet olan test verisinde 124 adet veri doğru sınıflandırılmıştır. Eğitimde başarı oranı %100 olmasına rağmen test aşamasında başarı oranı $(124/125) \times 100$ olarak hesaplanmış ve %99.2 olarak bulunmuştur. Daha sonra $k=1$ değeri için Fine k-NN yöntemi tekrar denenmiştir. $k=1$ değeri için eğitim başarı oranı %100 olarak bulunmuş ve test edilmiştir. Çıktı verileri incelendiğinde $k=1$ için Fine k-NN yöntemi ile araçlar tekrar %99.2 başarı oranında sınıflandırılabilmiştir.



Şekil 4.21. Farklı k-NN yöntemlerinde eğitim doğruluk oranları



Şekil 4.22. k-NN yönteminde eğitim aşamasını gösteren hata matrisi

Yapılan çalışmalar özetlenecek olursa, bu tez çalışmasında 5 farklı modeldeki otomobilin motor sesinden, otomobillerin modellerinin tanınması üzerine çalışılmıştır. İlk olarak tüm araçlardan 50'şer adet ses kaydı aynı ortamda alınmıştır. Tüm ses kayıtları net olarak 10'ar sn olması için 10 sn üzerindeki kısımları Audacity programı kullanılarak kırpılmıştır. Ses verilerinin incelenmesi sonucu öznelilikler çıkarılmıştır. Sınıflandırma ilk olarak ileri beslemeli yapay sinir ağları kullanılarak farklı gizli katman ve katmanlarda bulunan farklı nöron sayıları ile yapılmıştır. Ancak gizli katman sayısının artması eğitim için gerekli süreyi de arttıracakı düşünülerek deneme yanılma yöntemi ile 3 ve 4 gizli katman sayısında, gizli katman sayısının ağı performansı etkisini incelemek için işlem yapılmıştır. Çalışma, 17 girişe sahip ileri beslemeli yapay sinir ağının 3 katman sayısına sahip gizli katmanlarda 7 nöron ve çıkış katmanında 5 nöron olmak üzere ve 4 gizli katman sayısına sahip gizli katmanlarda 5 nöron ve çıkış katmanında da 5 nöron olacak şekilde yapılmıştır. Gizli katmanlarda hiperbolik tanjant (tansig) ve çıkış katmanında lineer fonksiyon, aktivasyon fonksiyonları olarak belirlenmiştir. Gizli katmanlarda 7 nöron ve çıkış katmanında 5 nöron bulunan 3 katmanlı ileri beslemeli yapay sinir ağı eğitilirken eğitim çıktısı için ilk satır 0-25 sütunları arasında 1 ve 1 değerine yakınsa 1. araç, ikinci satır. 25-50 sütunları arasında 1 ve 1 değerine yakınsa 2. Araç, üçüncü satır 50-75 sütunları arasında 1 ve 1 değerine yakınsa 3. Araç, dördüncü satır 75-100 sütunları arasında 1 ve 1 değerine yakınsa 4. araç ve beşinci satır 100-125 sütunları arasında 1 ve 1 değerine yakınsa 5. araç olacak şekilde yapılmıştır. Yani çıkış sayısı 5'tir ve her grubun hedef çıktısı (1, 0, 0, 0, 0), (0, 1, 0, 0, 0), (0, 0, 1, 0, 0), (0, 0, 0, 0, 1) beşli değerleri olarak verilmiştir. Çalışmada eldeki verilerin %50'lik kısmı olan 125 veri eğitim için geri kalan %50'lik kısım olan 125 veri test için kullanılmıştır. Tüm denemelerde yapay sinir ağları Levenberg-Marquardt öğretim algoritması kullanılarak eğitilmiştir.

3 katmanlı yapay sinir ağı test çıktısı kontrol edildiğinde 125 adet test verisi içinde 6 adet veri yanlış tanımlamıştır. Bu durumda $125 - 6 / 125 \times 100$ hesaplaması ile %95.2 başarı oranı bulunmuştur. Daha sonra 4 gizli katman sayısına sahip gizli katmanlarda 5 nöron ve çıkış katmanında da 5 nöron olan, gizli katmanlarda tansig ve çıkış katmanında lineer fonksiyon, aktivasyon fonksiyonu olarak belirlenmiş olan ileri beslemeli yapay sinir ağı modeli eğitilmiş ve test edilmiştir. Test çıktıları kontrol edildiğinde 1 veri hatası görülmüş ve $125 - 1 / 125 \times 100$ hesaplaması ile %99.2 başarı oranı bulunmuştur.

Destek vektör makineleri yönteminde, Cubic, Lineer ve Fine Gaussian SVM yöntemleri ile denemeler yapılmıştır. Destek vektör makineleri yönteminde k-Kat Çapraz Doğrulama algoritması kullanılarak eldeki verilerin eğitimde ve test aşamasında kullanılanları rastgele belirlenmiştir. k-Kat Çapraz Doğrulama yönteminin avantajı rastgele tekrarlanan alt örnekleme üzerinden elde edilen bütün grupların hem eğitim hem de sınıflandırma için kullanılabilir olmasıdır (Akşahin 2010). Eğitim aşaması 3-Kat ve 5-Kat çapraz doğrulama algoritması kullanılarak yapılmıştır. Şekil 4.20'de görüldüğü üzere 5-Kat çapraz doğrulama algoritması kullanılarak Lineer SVM çözüm yönteminde eğitim %100 doğruluk oranında, Cubic SVM yönteminde eğitim % 98.4 doğruluk oranında ve Fine Gaussian SVM çözüm yöntemi kullanıldığında eğitim %71.2 doğruluk oranında yapılmıştır. Test çıktıları tanımlaması şu şekilde yapılmıştır; İlk olarak değişkenler satır olarak tanımlanmıştır. 0-25 satır aralığı 1 değerini gösterirse 1. araç, 25-50 satır aralığı 2 değerini gösterirse 2. araç, 50-75 satır aralığı 3 değerini gösterirse 3.

araç, 75-100 satır aralığı 4 değerini gösterirse 4.araç ve 100-125 satır aralığı 5 değerini gösterirse 5. araç tanınmış olacaktır. Eğitimde %100 doğruluk oranına ulaşılan Lineer SVM çözüm yönteminde tüm satırlar istenen değerlerde çıkmış ve $125/125 \times 100$ hesaplaması yapılarak %100 sınıflandırma yapılmıştır.

Son olarak k-En Yakın Komşuluk yöntemi ile sınıflandırma çalışması yapılmıştır. Farklı k değerlerinde olan Fine KNN, Medium KNN, Coarse KNN, Cosine KNN, Cubic KNN ve Weighted KNN çözüm yöntemleri denenmiştir. Destek Vektör Makineleri yönteminde uygulandığı gibi k-Kat Çapraz Doğrulama Algoritması kullanılarak eldeki veriler eğitim ve test aşamasında rastgele belirlenmiştir. Eğitim işlemi, 3-Kat ve 5-Kat çapraz doğrulama algoritmaları kullanılarak yapılmıştır. Şekil 7.21'de görüldüğü üzere 5-Kat çapraz doğrulama algoritması kullanılarak Fine kNN çözüm yönteminde eğitim %100 doğruluk oranında, Medium kNN çözüm yönteminde eğitim %98.4 doğruluk oranında, Coarse kNN yöntemine eğitim %20 doğruluk oranında, Cosine kNN yönteminde eğitim %97.6 doğruluk oranında, Cubic kNN yönteminde eğitim %96.8 doğruluk oranında ve Weighted kNN yönteminde eğitim %98.4 doğruluk oranında yapılmıştır. Destek Vektör Makineleri yönteminde olduğu gibi test çıktıları tanımlaması şu şekilde yapılmıştır; İlk olarak değişkenler satır olarak tanımlanmıştır. 0-25 satır aralığı 1 değerini gösterirse 1.araç, 25-50 satır aralığı 2 değerini gösterirse 2. araç, 50-75 satır aralığı 3 değerini gösterirse 3. araç, 75-100 satır aralığı 4 değerini gösterirse 4.araç ve 100-125 satır aralığı 5 değerini gösterirse 5. araç tanınmış olacaktır. Eğitimde %100 doğruluk oranına ulaşılan k=1 değeri için Fine kNN çözüm yönteminde, bir veri hariç diğer satırlardaki çıktı verileri araçların tanındığını anlatan numaralarda yani istenen değerlerde çıkmış ve $124/125 \times 100$ hesaplaması yapılarak %99.2 başarı oranında sınıflandırma yapılmıştır.

5. SONUÇ

Bu çalışmada, farklı araçların motor seslerinden araçların modellerinin tanınması amaçlanmıştır. Tanıma işlemi, ses verilerinin toplanması ile başlamış daha sonra bu ses verilerinin welch yöntemi ile güç spektrum yoğunlukları hesaplanmış ve grafikleri çizdirilmiştir. PSD grafikleri ayrı ayrı analiz edilerek 17 adet farklı frekans bölgesi belirlenmiş ve bu frekans bölgelerine karşılık gelen güç spektrum değerleri öznitelik olarak alınmıştır. Öznitelik matrisi oluşturulmuştur. Bu öznitelik matrisleri ile YSA, SVM ve k-NN yöntemleri kullanılarak sınıflandırma çalışmaları yapılmıştır.

Sınıflandırma çalışmalarında toplam 5 araç ve her araçtan alınmış 50'şer adet ses kaydı bulunmaktadır. Araçların rölanti halinde çalışırken motor sesleri kaydedilmiştir. Literatür incelendiğinde araçların sınıflandırma çalışmaları görülmüş ancak araçların rölanti halinde çalışırken motor sesleri kullanılarak yapılmış sınıflandırma çalışmalarına rastlanmamıştır. Ayrıca, araçların sınıflandırma çalışmaları incelendiğinde, güç spektrum yoğunluklarının hesaplanmasında literatürde sıklıkla kullanılan Mel Frekans Kepstrum Katsayıları yöntemi yerine Welch yöntemi kullanılarak çalışmaya ayrıca özgünlük kazandırılmıştır. Sınıflandırma işlemlerinin, literatürde sıklıkla k- En Yakın Komşuluk yöntemi ve Destek Vektör Makineleri yöntemlerinin karşılaştırmaları ile yapıldığı görülmüştür. Bu yöntemlere ek olarak çalışmaya Yapay Sinir Ağları yöntemi de eklenerek, sınıflandırma çalışması 3 farklı yöntem kullanılarak yapılmıştır.

Sınıflandırma çalışmaları, farklı katman ve nöron sayılarında ileri beslemeli yapay sinir ağları ile yapılmıştır. 4 gizli katman her katmanda 5 nöron bulunan ve çıkış katmanında 5 nöron bulunan Levenberg-Marguardt öğretim algoritması kullanılan ileri beslemeli yapay sinir ağları kullanılarak %99.2 başarı oranında sınıflandırma yapılmıştır. Destek Vektör makineleri ve k- En Yakın Komşuluk yöntemleri kullanılarak yapılan sınıflandırma çalışmalarında ise sırasıyla %100 ve %99.2 başarı oranlarında sınıflandırma yapılarak araçlar birbirinden oldukça yüksek yüzde oranlarında ayrıştırılabilmektedir. Literatürde araçların farklı bölgelerindeki sinyaller veya sesler kullanılarak sınıflandırılmasına yönelik çalışmalara rastlanmış ancak rölanti halindeki motor sesleri kullanılarak sınıflandırma çalışmalarına rastlanmamıştır. Bu nedenle araçların sınıflandırılmasına yönelik yapılan bu çalışma, araç olarak otomobillerin ve ses olarak otomobil motor seslerinin kullanılması ile özgün bir nitelik taşıdığı düşünülmektedir.

Tez çalışmasında kullanılan araçlar incelendiğinde, 5 farklı modelde olan ancak içlerinde 2 adet aynı motora sahip farklı modelde araç bulunmaktadır. Sınıflandırmadaki başarı oranlarına bakıldığında aynı motora ait olan araçlarında birbirlerinden ayrıştırılabildiği görülmektedir. Motor seslerinin frekansları, araçta aynı motor olsa dahi farklı gövde tipinde olduğundan dolayı farklılık gösterdiği düşünülmektedir. Ayrıca çalışmada kullanılan araçlar içinde benzinli motora sahip 1 adet araçta bulunmaktadır. Sınıflandırmadaki başarı oranlarına bakılarak aynı motora sahip farklı gövde tipindeki araçların yanında farklı yakıt tipine sahip araçların da ayrıştırılabildiği görülmektedir.

Araçların motor sesleri kullanılarak modelinin tanınması amacıyla yapılan bu tez çalışmasının, ileride bu alanda yapılabilecek deneysel çalışmalara ışık tutması amaçlanmaktadır. Ayrıca ileride araçların motorlarında meydana gelebilecek olan arızaların tespitine yönelik bir çalışmanın fazla sayıda araca ulaşılarak ve farklı

dönemlerde ulaşılan bu araçlardan fazla sayıda ses örnekleri toplanarak oluşturulacak bir veri kütüphanesi ile ve bu tez çalışmasında uygulanan yöntemler kullanılarak yapılabileceği düşünülmektedir.

Yapılan sınıflandırma çalışması sonucunda elde edilen sınıflandırmadaki yüksek başarı oranları, araçların motor sesleri kullanılarak ayrıştırılabileceğini bir başka deyişle tanınabileceğini göstermektedir.



6. KAYNAKLAR

- Proakis, J. G., Manolakis, D. G. 2010. Sayısal Sinyal İşleme. Nobel Yayın Dağıtım, Ankara, 1077 s.
- Demirkale, S. Y. 2007. Çevre ve Yapı Akustiği. Birsen Yayınevi, İstanbul, 510 s.
- Önen, U. 2016. Ses Kayıt ve Müzik Teknolojileri. Çitlembik Yayınları, İstanbul, 480 s.
- Özgüven, N. 1986. Endüstriyel Gürültü Kontrolü. TMMOB Makine Mühendisleri Odası Oda Yayınları, Yayın No: 118, Ankara, 178 s.
- Davis, K. H., Biddulph, R. and Balashek, S. 1952. Automatic Recognition of Spoken Digits. The Journal of the Acoustical Society of America, 24 (6): 637-642.
- Olson, K. H. and Belar, H. 1956. Phonetic Typewriter. The Journal of the Acoustical Society of America, 28 (6): 1072-1081.
- Türkoğlu, İ., Arslan, A. 1996. Yapay Sinir Ağları İle Bozuk Örüntü Tanıma. Fırat Üniversitesi Fen ve Müh. Bilimleri Dergisi, 147-158, Elazığ.
- Altınörs, A., Avcı, E., Biçer, Z. 2008. Sayısal Modülasyon Tanıma Sistemleri İçin Bayes Karar Kuralları Sınıflandırıcısının Kullanımı. Natural Applied Sciences, Vol:3, No:1, pp. 117-123.
- Nabiyev, V.V. 2012. Yapa Zeka. Seçkin Yayıncılık, Ankara, 776 s.
- Ölmez, T., Dokur, Z. 2009. Uzman Sistemlerde Örüntü Tanıma. İstanbul Teknik Üniversitesi, İstanbul, pp. 1-15.
- Übeyli, E. D. 2004. Doppler İşaretlerine Spektral Analiz Tekniklerinin Uygulanması Ve Yapay Sinir Ağları İle Sınıflandırılması. Doktora Tezi, Gazi Üniversitesi, Ankara, 145s.
- Mikaeili, M. 2015. Doppler Ultrason Görüntüleme Sistemlerinde Yeni Bir Uyarlamalı Spektral Güç Yoğunluk Tahmin Yöntemi Kullanarak Çözünürlüğün İyileştirilmesi. Yüksek Lisans Tezi, Gazi Üniversitesi, Ankara, 91 s.
- Erdemir, M. 2015. Sinyal İşleme. https://e-bergi.com/y/sinyal_isleme/ [Son erişim tarihi: 07.03.2018]
- Keller, E. 1994. Fundamentals of speech synthesis and speech recognition: basic concepts, state of the art and future challenges. John Wiley and Sons Ltd., United Kingdom, 394 p.
- Aydın, Ö. 2005. Yapay sinir ağlarını kullanarak bir ses tanıma sistemi geliştirilmesi. Yüksek Lisans Tezi, Trakya Üniversitesi, Edirne, 82 s.
- Bayrak, T. 2012. Uyku Apnesi Parametrelerinin Cerrahi Tedavi Öncesi Ve Sonrasında Değerlendirilmesi. Yüksek Lisans Tezi, Başkent Üniversitesi, Ankara, 90 s.
- Solomon, O., M., Jr. 1991. PSD Computations Using Welch's Method. Sandia National Laboratories, California, 54 p.
- Wu, H., Siegel, M., Khosla, P. 1998. Vehicle Sound Signature Recognition by Frequency Vector Principal Component Analysis. IEEE Instrumentation and Measurement Technology Conference, St. Paul, USA, pp. 429-434.

- Aykun, İ., Karşılıgil, M. E. 2009. Ship Classification by Sound Signature. 17th Sinyal İşleme ve Uygulama Sempozyumu, Antalya, pp. 101-104
- Özgündüz, E., Türkmen, H. İ., Şentürk, T., Karşılıgil, M. E., Yavuz, A. G. 2010. Vehicle Identification using Acoustic and Seismic Signals. IEEE 18. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Diyarbakır, pp. 941-944.
- Doğan, D. 2017. Road-Types Classification using Audio Signal Processing and SVM Method. 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Antalya
- Güvensan, M. A., Tayşi, Z. C. 2010. Environmental Sound Classification for Recognition of House Appliances. IEEE 18. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Diyarbakır, pp. 431-434
- Sağıroğlu, Ş., Beşdok, E., Erler, M. 2003. Mühendislikte Yapay Zeka Uygulamaları. Ufuk Yayınları, Kayseri, 426 s.
- Soytürk, M. A. 2005. Sayısal Kenar Çıkarma ve Yapay Sinir Ağları Yardımıyla Araç Tanıma. Yüksek Lisans Tezi, Erciyes Üniversitesi, Kayseri, 75 s.
- Eray, O. 2008. Destek Vektör Makineleri İle Ses Tanıma Uygulaması. Yüksek Lisans Tezi, Pamukkale Üniversitesi, Denizli, 79 s.
- Uslu, M. 2016. Yapay Sinir Ağları (YSA) Nedir?. <http://kod5.org/yapay-sinir-aglari-ysa-nedir/> [Son erişim tarihi: 06.04.2018]
- Anonim 1: www.websitem.gazi.edu.tr/site/saltan/files/download/id/93003 [Son erişim tarihi: 06.04.2018]
- Öztemel, E. 2006. Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul, 231 s.
- Ataseven, B. 2013. Yapay Sinir Ağları İle Öngörü Modellemesi. Marmara Üniversitesi Sosyal Bilimler Enstitüsü Öneri Dergisi, Cilt:10, Sayı:39, pp. 101-115
- Şeker, Ş. E. 2008. SVM (Support Vector Machine, Destek Vektör Makinesi). <http://bilgisayarkavramlari.sadievrenseker.com/2008/12/01/svm-support-vector-machine-destekci-vektor-makinesi/> [Son Erişim Tarihi: 11.04.2018]
- Kavzaoğlu, T., Çölkesen, İ. 2010. Destek Vektör Makineleri İle Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. Harita Dergisi, Ankara, pp. 73-82
- Zengin, H. A. 2017. K En Yakın Komşu Methodu. <http://yazilimagiris.com/2017/11/k-en-yakin-komsu-methodu-k-nearest-neighborhood/> [Son erişim tarihi: 12.04.2018]
- Yazgaç, B. G. 2016. Süne ve Kımıl Zararlılarının Ses İşleme Yöntemleri ile Sınıflandırılması ve Bir Gömülü Sistem Gerçeklemesi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul, 95 s.
- Aydın, İ. 2008. Otomobillerde Kullanılan İzolasyon Malzemelerinin Emme Katsayılarının Ölçülmesi ve Uygun Malzeme Kalınlığının Belirlenmesi. Yüksek Lisans Tezi, Gazi Üniversitesi, Ankara, 57s.
- Oppenheim, A. V., Willsky, A. S., Nawab, H. 1997. Signals & Systems. Prentice Hall, Inc., New Jersey, 491 p.

- Rangayyan, R. M. 2002. Biomedical Signal Analysis. Wiley- IEEE Press, New Jersey, 720 p.
- Challen, B., Baranescu, R. 1999. Diesel Engine Reference Book. Oxford; Butterworth-Heinemann Ltd., United Kingdom, 682 p.
- Demir, A. 2017. Gürültü Kaynakları ve Gürültü Ölçümü. http://www.abdullahdemir.net/wp-content/uploads/2017/12/GURULTU-KAYNAKLARI-VE-TESTLERI_2017.pdf [Son erişim tarihi: 02.05.2018]
- Akşahin, M. F. 2010. Uyku Apnesi Türlerinin Sınıflandırılması. Doktora Tezi, Başkent Üniversitesi, Ankara, 166 s.
- Dursun, M. 2009. EEG Sinyallerinde Uyku İçciklerinin Zaman ve Frekans Domeni Özellikleri Kullanılarak Analizi. Yüksek Lisans Tezi, Selçuk Üniversitesi, Konya, 86 s.
- Mut, O., 2005.Konuşmacı Tanıma. Yüksek Lisans Tezi, Gebze Yüksek Teknoloji Enstitüsü, Kocaeli, 44s
- Toprak, İ. B. 2007. EEG Sinyallerinin Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Analizi. Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, Isparta, 89s.
- Koçak, O., Beytar, F., Fırat, H., Telatar, Z., Eroğul, O. 2016. Comparison of Non-Parametric PSD Detection Methods in the Analysis of EEG Signals in Sleep Apnea. Tıp Teknolojileri Kongresi, pp. 366-369
- Sokouti, B., Haghypour, S., Tabrizi, A. D. 2014. A framework for diagnosing cervical cancer disease based on feedforward MLP neural network and ThinPrep histopathological cell image features. Neural Computing and Applications, Springer, Vol:24, pp. 221-232

ÖZGEÇMİŞ

EFECAN KARAMAN

efecan.karaman@hotmail.com



ÖĞRENİM BİLGİLERİ

Yüksek Lisans 2014-2018	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Anabilim Dalı
Lisans 2009-2013	Süleyman Demirel Üniversitesi Mühendislik Fakültesi, Makine Mühendisliği Bölümü

MESLEKİ VE İDARİ GÖREVLER

Araştırma Görevlisi 2017-2018	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Bölümü
UTAŞ Savunma Sanayi ve Tic. A.Ş. 2016-2017	Makine Mühendisi