

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKUSTİK SİNYAL TEMELLİ TRAFİK
YOĞUNLUĞU TESPİTİ

FİKRET ÖZTÜRK
YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

GEBZE
2015

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKUSTİK SİNYAL TEMELLİ TRAFİK
YOĞUNLUĞU TESPİTİ

FİKRET ÖZTÜRK
YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMANI
YRD. DOÇ. DR. ALİ KÖKSAL HOCAOĞLU

GEBZE
2015

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**ACOUSTIC SIGNAL BASED TRAFFIC
DENSITY DETECTION**

FİKRET ÖZTÜRK
**A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE**
DEPARTMENT OF ELECTRONIC ENGINEERING

THESIS SUPERVISOR
ASST. PROF. DR. ALİ KÖKSAL HOCAOĞLU

GEBZE
2015



YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 29/06/2015 tarih ve 2015/41 sayılı kararıyla oluşturulan jüri tarafından 14/07/2015 tarihinde tez savunma sınavı yapılan Fikret ÖZTÜRK'ün tez çalışması Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE
(TEZ DANIŞMANI) : Yrd.Doç.Dr. Ali Köksal HOCAOĞLU

ÜYE : Yrd.Doç.Dr. Sultan ALDIRMAZ

ÜYE : Yrd.Doç.Dr. Serdar Süer ERDEM

ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun

...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Bu çalışmada, araçların oluşturduğu akustik gürültü sinyalinden trafik yoğunluğu tespiti yapılmıştır. Araçların oluşturduğu akustik gürültü motor gürültüsü, hava türbülans gürültüsü, tekerleğin yerle temasından kaynaklı gürültü, egzoz gürültüsü ve korna gürültüsünden oluşmaktadır. Bu gürültülerin her biri trafik yoğunluk durumuna göre değişmektedir. Örneğin; trafiğin yoğun olduğu zamanlarda motor ve korna gürültüsü yoğun iken, trafik akışkan iken ise hava türbülans ve tekerlek gürültüsü daha yoğundur. Bu farklılıktan faydalanılarak trafik yoğunluğu sıkışık, orta ve akışkan olarak üç kategoriye ayrılması mümkün olabilmektedir.

Bu çalışmada, trafik yoğunluğunun akustik sinyal analizine dayalı olarak tespiti konusunda bugüne kadar yapılan çalışmalarda sık olarak kullanılan MFCC (Mel Filter Kepstrum Katsayıları) özniteliği yardımıyla E-5 karayolundaki trafik yoğunluğu %68 doğrulukla tespit edilebilmiştir. Başarı oranını artırmak için MFCC öznitelikleri farklı parametrelerle de oluşturularak Bayes, K-NN ve SVM sınıflandırıcılar kullanılarak trafik yoğunluğu tespit başarıları irdelenmiştir. En yüksek performansı sağlayan parametreler ve sınıflandırıcı seçildikten sonra öznitelik seçme ve indirgeme yöntemlerinin performans üzerindeki etkisi incelenmiştir.

Yağmurlu havada tekerleğin yer ile temasında oluşan gürültü ile yağmursuz havada tekerleğin oluşturduğu gürültünün farklı olması gözleminden yola çıkarak araçların oluşturduğu akustik gürültü sinyalinin hava koşullarına göre değişebileceği sonucuna varılmıştır. Hava koşullarının dikkate alınması durumunda trafik yoğunluğu tespit performansının artıp artmayacağına yönelik çalışmalar yapılmıştır. Hava koşullarının yağmurlu olup olmamasının dikkate alınması halinde başarı oranının arttığı gözlenmiştir.

Anahtar Kelimeler: Akustik, Trafik Yoğunluğu, Trafik Monitör.

SUMMARY

In this study, traffic density is detected by acoustic noise signals formed by the vehicles. The acoustic noise signals formed by the vehicles are engine noise, air turbulence, the noise of the wheels touching the floor, exhaust noise and the horn noise. All these noise signals change according to the traffic density. For example, engine noise and horn noise is dense when the traffic is busy, but when the traffic is fluent air turbulence and wheel noise is more dense. By using this variation, the traffic density is categorized into three classes; busy, normal and fluent.

In this study, the traffic density in the E-5 highway is determined by %68 accuracy, by using MFCC attributes which are frequently used in the studies conducted up to now that are related with the detection of the traffic density by acoustic noise signal analysis. In order to increase the success rate, MFCC attributes are formed by different parameters and the traffic density detection performance is examined when Bayes, K-NN and SVM classifiers are used. After choosing the best performed parameters and classifier, the effect of the attribute selection and reduction methods on the performance is examined.

On the basis of the difference of the noise of the wheels under rainy weather and dry-weather conditions, it was concluded that acoustic noise signals change according to the weather conditions. Studies have been made that to examine that if the performance of the traffic density detection increases when the weather conditions are considered. It was observed that the success rate is higher when the weather and rain conditions are considered.

Key Words: Acoustic, Traffic Density, Traffic Monitoring.

TEŐEKKÖR

BaŐta, yÖksek lisans eđitimimde ve akademik hayatımda desteđini ve yardımlarını hiŐbir zaman esirgemeyip bilgisi ile bu alıŐmanın oluŐmasının yolunu aan danıŐmanım Yrd. Do. Dr. Ali KÖksal HOCAOđLU'na,

BÖtÖn alıŐmam boyunca, özellikle E-5 karayolunda veri toplarken beni yalnız bırakmayan deđerli alıŐma arkadaşlarım Onur GÖRSOY ve Hakan ÖZDEMİR'e ve göstermiş olduđu desteklerinden dolayı deđerli aileme en içten teŐekkÖrlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
TABLolar DİZİNİ	xii
1. GİRİŞ	1
1.1. Türkiye'deki Durum	2
1.2. Hipotez	3
1.3. Tezin Organizasyonu	4
2. LİTERATÜR İNCELEMESİ	6
2.1. Sensör Teknolojisi	6
2.1.1. Aktif Sensörler	6
2.1.2. Pasif Sensörler	7
2.2. Akustik Sinyalin Yapısı	8
2.2.1. Motor Sesi	9
2.2.2. Tekerlek Sesi	9
2.2.3. Hava Türbülansı Sesi	10
2.2.4. Egzoz Sesi	10
2.2.5. Korna Sesi	11
2.3. Akustik Sensör ve Kullanım Şekilleri	11
2.4. Ön İşleme	12
2.4.1. Ön Vurgulama	12
2.4.2. Çerçeveleme	13
2.4.3. Pencereleme	14
2.5. Öznitelik Çıkarımı	15
2.5.1. Zaman Uzayı	16
2.5.2. Frekans Uzayı	17

2.5.3. Zaman - Frekans Uzayı	24
2.6. Öznitelik İndirgeme	24
2.6.1. Temel Bileşenler Analizi	25
2.6.2. Doğrusal Ayırışım Analizi	25
2.6.3. Öznitelik Seçimi	25
2.7. Sınıflandırma	27
2.7.1. En Yakın Komşu	27
2.7.2. Bayes Sınıflandırma	28
2.7.3. Destek Vektör Makinası	29
3. TRAFİK YOĞUNLUĞU TESPİT YAKLAŞIMI	30
4. DENEYSEL SONUÇLAR	36
4.1. Veri Setinin Oluşturulması	36
4.2. Literatürdeki Çalışmanın Gerçeklemesi	37
4.3. Verileri Önışleme	38
4.3.1. Spektrum Analizi	39
4.3.2. Sınıflandırma Analizi	40
4.4. MFCC Özniteliklerinin Oluşturulması	41
4.5. Farklı Parametreler ile MFCC Uygulamaları	41
4.6. Öznitelik Seçme/İndirgeme	47
4.6.1. Öznitelik Seçme	47
4.6.2. Öznitelik İndirgeme	52
4.7. Hava Koşulları Dikkate Alındığında	54
4.7.1. Yağmurlu Hava Koşullarına Göre Öznitelik Seçimi	55
4.7.2. Yağmursuz Hava Koşullarına Göre Öznitelik Seçimi	57
5. SONUÇ ve GELECEK ÇALIŞMALAR	58
KAYNAKLAR	60
ÖZGEÇMİŞ	65

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler ve Açıklamalar

Kisaltmalar

CWT	: Continuous Wavelet Transform
DCT	: Discrete Cosine Transform
DWT	: Discrete Wavelet Transform
FDR	: Fisher's Discriminant Ratio
FFT	: Fast Fourier Transform
GMM	: Gaussian Mixture Model
GZIS	: Gerçek Zamanlı İşletim Sistemi
HLA	: Harmonic Line Association
İHA	: İnsansız Hava Aracı
İTS	: Intelligent Transportation System
K-NN	: K – Nearest Neighbor
LDA	: Linear Discriminant Analysis
MFCC	: Mel-Frequency Cepstral Coefficient
PCA	: Principal Components Analysis
PDF	: Probability Density Function
PSE	: Power Spectrum Estimation
RBF-SVM	: Radial Basis Function- Support Vector Machine
STFT	: Short Time Fourier Analysis
SVM	: Support Vector Machines

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
1.1: İstanbul trafik yoğunluk haritası.	3
1.2: Trafik yoğunluğu tespiti tasarım aşamaları.	5
2.1: Hız-Ses seviyesi.	10
2.2: Akustik sinyalin ön işleme aşamaları.	12
2.3: Önvurgu filtresi frekans tepkisi.	13
2.4: Ses işaretinin çerçevelere bölünmesi.	14
2.5: MFCC öznitelik çıkarım aşamaları.	19
2.6: Ses sinyali. a) Zaman uzayı, b) Frekans uzayı	21
2.7: Mel filtre bankası.	22
2.8: Frekans ve Mel-frekans arasındaki bağıntı.	22
3.1: Trafik yoğunluğu tespit tasarım aşamaları.	30
3.2: Trafik yoğunluğu akustik spektrumları.	31
3.3: Öznitelik vektör histogramı.	33
3.4: Yağmursuz-Yağmurlu havada trafik yoğunluğu akustik spektrumları.	34
3.5: Hava koşulları ile trafik yoğunluğu tespit yaklaşım aşamaları.	35
4.1: Akustik sinyalin önişlemsiz-önişlemli spektrum analizleri.	39
4.2: Mel-filtre sayısına göre sınıflandırıcı performans histogramları.	43
4.3: Öznitelik Sayısına göre sınıflandırıcı performans histogramları.	44
4.4: Pencere Süresine göre sınıflandırıcı performans histogramları.	45
4.5: MFCC öznitelikleri ve Entropi ölçütü histogramı.	48
4.6: MFCC öznitelikleri ve FDR oranı histogramı.	49
4.7: MFCC öznitelik sayısı ve K-NN doğruluk histogramı.	51
4.8: Özdeğer (Eigenvalue) – PCA bileşen sayısı.	52
4.9: Yağmurlu hava öznitelikler ve K-NN doğruluk histogramı.	56
4.10: Yağmursuz hava öznitelikler ve K-NN doğruluk histogramı.	57

TABLolar DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
2.1: Tekli-Çoklu sensör karşılaştırılması.	11
4.1: E-5 Otoyolu veri setinin literatür çalışmasına göre performansları.	38
4.2: Ön işlemsiz - Ön işlemlili akustik sinyalin sınıflandırıcı performansları.	40
4.3: Ortalama ve standart sapmaya göre sınıflandırıcı performansları.	42
4.4: En yüksek performanstaki MFCC'nin parametrik değerleri.	46
4.5: Entropi ölçütünde MFCC özniteliklerin K-NN performansları.	48
4.6: FDR oranından elde edilen MFCC özniteliklerin K-NN performansları.	50
4.7: Öznitelik vektör histogramına göre en yüksek K-NN performansları.	51
4.8: Öznitelik seçme/indirgeme yöntemleri K-NN performansları.	53
4.9: Hava koşulları dikkate alınmadığında en yüksek K-NN performansları.	54
4.10: Yağmurlu hava koşullarında en yüksek K-NN performansları.	55
4.11: Yağmursuz hava koşullarında en yüksek K-NN performansları.	55
4.12: Yağmurlu hava koşullarına göre özniteliklerin K-NN performansları.	56
4.13: Yağmursuz hava koşullarına göre özniteliklerin K-NN performansları.	57

1. GİRİŞ

Dünya genelinde trafik yoğunluğu önemli bir problemdir. Artan araç sayısı, kentleşmenin artması ve nüfus yoğunluğunun artması sonucu dünya çapında trafik yoğunluğu da artmıştır [1]. Trafik yoğunluğunun olumsuz etkileri aşağıda ifade edildiği gibi altı başlıkta toplanabilir [1]-[4].

- Şehrin ulaşım alt yapısı verimliliğini azaltmaktadır,
- Yolculuk zamanını arttırmaktadır,
- Yakıt tüketimini artırmaktadır,
- Hava kirliliğini artırmaktadır,
- Araç kullanıcılarının yorgunluğunu artmaktadır,
- Araç kullanıcılarının sinirsel bozukluklarını artırmaktadır,

Trafik yoğunluğunun çözümü şehirlerin ulaşım alt yapısının daha verimli olmasını, araç kullanıcılarının zamandan ve yakıt tüketiminden kar etmesini, havadaki kirlilik oranının azalmasını ve araç kullanıcılarının sağlık problemlerinin azalmasını sağlayacaktır. Trafik yoğunluğu çözümü için geçmişten günümüze kadar birçok çalışma yapılmıştır. Özellikle gelişmiş ülkelerde Akıllı Ulaşım Sistemleri (ITS – Intelligent Transportation System) adı altında ulaşım sistemlerinde birçok çözüm sunulmuştur. Bunlar; şerit kontrolü, araç tespiti, araç hızı tespiti, trafik yoğunluğu tespiti, kaza tespiti ve akıllı trafik ışık kontrol vb. çözümlerdir. Bu çözümlerde ilk olarak manyetik detektör, hızölçer gibi algılayıcılar kullanılmaktaydı [1]. Bu algılayıcılar, kurulumları ve destekleri çok maliyetli olmasının yanında aynı zamanda kurulum ve destek esnasında trafik akışına engel olmasından dolayı geniş çaplı uygulanabilirliğe sahip değildir. Bundan dolayı, son on yılda ultrasound, radar, lazer, görüntü ve ses gibi algılayıcılar üzerine çalışmalar yapılmaktadır [1].

Akıllı Ulaşım Sistemlerinde kamera görüntüsüne dayalı olarak araç takibi ve trafik yoğunluğu tespiti çalışmaları olmasına karşın değişik ışık ortamlarından ve çevresel perdelemelerden dolayı nesne belirlemede bu çalışmaların yetersiz kaldığı gözlemlenmiştir. Görüntü işleme teknolojisinde önemli gelişmeler olmasına rağmen bu problemlere yüksek performanslı çözümler üretilmemiştir. Aynı zamanda görüntü işleme teknolojisi çok fazla hesaplama gerektiren fonksiyonlara sahip

olduğundan çok nitelikli ekipmanların kullanılması gerekmekte, dolayısıyla maliyeti yükseltmektedir. Bu nedenle geniş çaplı uygulanabilirliği çok mümkün olmamaktadır [5]-[9].

Gelişmiş ülkelerde Akıllı Ulaşım Sistemlerinde trafik yoğunluğunun ölçümünde magnetik loop dedektörü çok fazla kullanılan yöntemlerdendir. Ancak bu sensörün kurulumu ve teknik desteği çok maliyetlidir. Aynı zamanda bu sensör üzerinde yapılacak bakım işlemleri sırasında tüm trafiğin durdurulması gerekmektedir. Bu yöntem şerit temelli çalıştığı için trafiğin çok yoğun ve şerit düzeninin ihlal edildiği bölgelerde kullanılması çok iyi sonuç vermemektedir [10], [11].

Son on yıl içinde Akıllı Ulaşım Sistemlerinde akustik sinyal üzerine yapılan çalışmalar artmıştır[1]. Akustik sinyal kullanılarak araç hızı, araç tespiti, araç tanımlama ve trafik yoğunluğu tespiti gibi uygulamalar üzerine çalışmalar yapılmıştır [1], [2], [12]-[17]. Akıllı Ulaşım Sistemlerinde akustik sinyalin kullanılmasının en temel nedenleri kurulum maliyetinin, teknik destek maliyetinin düşük olması ve kurulum/destek zamanlarında trafik akışına herhangi bir engelinin olmamasıdır. Maliyetinin düşük olması geniş çaplı uygulamalar yapılmasının önünü açmaktadır [1].

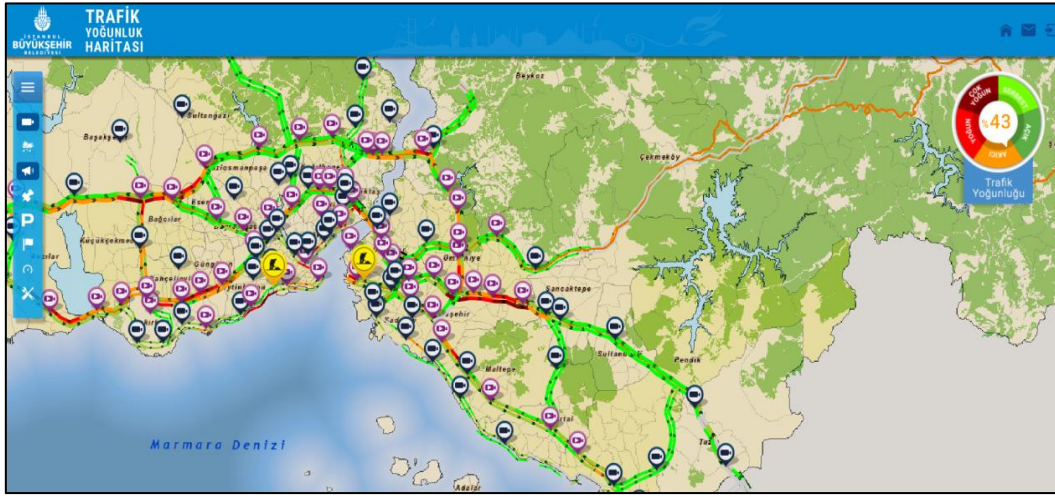
1.1. Türkiye'deki Durum

Türkiye'de trafik yoğunluğunun en çok olduğu il İstanbul olduğundan dolayı İstanbul Büyükşehir Belediyesi bu konu üzerine çalışmalar yapması için Trafik Kontrol Merkezi (TKM) kurmuştur. TKM trafik sinyalizasyon, trafik kontrol, trafik denetleme ve engelsiz trafik vb. konular üzerine çalışmalar yürütmektedir. Bu çalışmalardan biri İstanbul Trafik Yoğunluğu Haritası'nın üretilmesidir. Bu harita İstanbul'un büyük bir kesiminin trafik yoğunluk durumunu göstermektedir.

Sahada yer alan trafik ölçüm sistemleri tarafından Trafik Kontrol Merkezine iletilen anlık trafik yoğunluk verileri, Otomatik Yol ve Meteoroloji Gözlem Sensörlerinden alınan meteorolojik veriler ve diğer birimlerden alınan yol ağları üzerinde bulunan altyapı çalışmalarına ait bilgiler, işlenerek Sayısal Trafik Yoğunluk Haritası üzerinde sunulmaktadır. Oluşturulan bu harita web aracılığı ile yayımlanarak sürücülerin ve yolcuların ekonomik ve konforlu bir seyahat için

alternatif güzergâhlara yönlendirilmelerini ve seyahatlerini planlamaları sağlanmaktadır.

Kullanıcılara sunulan arayüz Şekil 1.1’de görüldüğü gibidir. Çalışmamız sırasında gözlem yaptığımız konumun o andaki trafik yoğunluğu bilgisini almak için TKM’nin Trafik Yoğunluk Haritası kullanılmıştır.



Şekil 1.1: İstanbul trafik yoğunluk haritası.

1.2. Hipotez

Bu çalışmada, “yol kenarındaki akustik sinyal kullanılarak trafik yoğunluğu tespiti”nin yapılabileceği ve “hava koşulları dikkate alındığı zaman trafik yoğunluğu tespitinin daha yüksek doğrulukla” elde edilebileceği ileri sürülmüştür.

Araçlar dururken veya hareket halindeyken çevreye gürültü yayarlar. Bu gürültü, aracın rölanti gürültüsü, aracın lastiklerinin yer ile temasında oluşan gürültü, aracın hareketi sırasında oluşan hava türbülansının gürültüsü, araç motorunun gürültüsü ve korna gürültüsünden oluşmaktadır. Araçların oluşturduğu gürültüde bazı gürültü kaynakları duruma göre daha fazla ağırlıklıdır [18]. Örneğin; otobanda hızlı giden araçları dinlediğimiz zaman duyduğumuz gürültü sinyalinde, lastiğin yer ile sürtünmesi sonucu oluşan gürültü ve hava türbülansının gürültüsü ağır bastığını gözlemleriz. Trafik çok yoğun olduğu bir yolda sadece araç rölanti ve korna gürültülerinin yoğunlukta olduğu gözlemlenmiştir [6], [7].

Farklı trafik yoğunluklarına göre farklı gürültü spektrumu elde edebiliriz [1], [19]. Böylece yol kenarındaki akustik ses sinyallerine göre trafik yoğunluk durumu

ayırt edilebilir. Tyagi çalışmasında, trafik yoğunluğu durumunu serbest-akış (40 km/s ve üstü), orta-akış (10-40 km/s) ve sıkışık (0-10 km/s) olmak üzere üç temel başlık altında sınıflandırmıştır [1]. Bu çalışma kapsamında da benzer bir sınıflandırma kullanılmıştır.

1.3. Tezin Organizasyonu

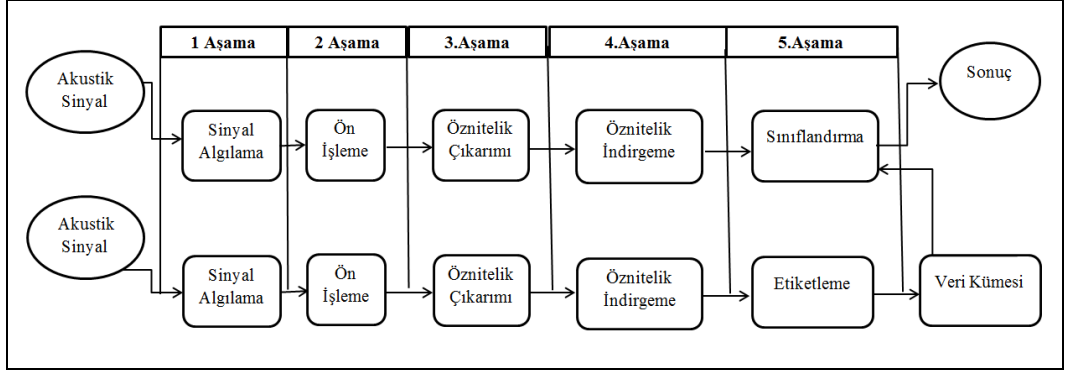
Bu çalışmanın hipotezi “yol kenarındaki akustik sinyal kullanılarak trafik yoğunluğu tespiti”nin yapılabileceğidir. Sesin algılanmasından trafik yoğunluğu tespitini yapılmasına kadar geçen süreç Şekil 1.2’de aşama aşama gösterilmiştir. Bu aşamalaradaki yöntemlere ait literatür çalışmaları Bölüm 2’de, tezde kullanılacak yöntem ve farklılıklar Bölüm 3’te, yöntemlerin deneysel sonuçları Bölüm 4’te ve sonuçlar, gelecek çalışmalar da Bölüm 5’te yer almaktadır. Bölümler aşağıda birer paragraf halinde detaylandırılmıştır.

Bölüm 2’de literatür çalışmalarında kullanılan sensörler, akustik sinyalin yapısı, öznitelik çıkarma ve indirgeme yöntemleri ve sınıflandırma yöntemleri incelenmiştir.

Bölüm 3’te trafik yoğunluğu durumlarının akustik sinyal spektrumları ve öznitelik vektör histogram olarak adlandırılan yöntemin akış diyagramı incelenmiştir.

Bölüm 4’te trafik yoğunluğu tespiti için yol kenarındaki akustik gürültü sinyalinin sensörler ile algılanması, akustik sinyalin işlenmesi, özniteliklerin çıkarımında kullanılan MFCC yöntemi, MFCC yönteminde parametre değişiklikleri yapılarak en iyi MFCC uygulaması tespiti, belirlenen MFCC uygulaması ile elde edilen özniteliklerden boyut indirgeme ve seçme yöntemleri kullanılarak en iyi performans gösteren özniteliklerin seçilmesi ve hava koşulları dikkate alınarak performansı artıracak yağmurlu hava ve yağmursuz hava koşullarına göre yeni öznitelik grubunun seçilmesi incelenmiştir.

Bölüm 5’te bir önceki bölüme ait çalışmaların adım adım performanstaki artışı ve özellikle referans alınan Tyagi çalışmasındaki yöntemlerin E-5 karayolunda toplanan veri setimiz ile test edilmesi sonucu elde edilen performansın bu çalışmada elde edilen performans ile karşılaştırılması ve gelecekte yapılabilecek çalışmalar işlenmiştir.



Şekil 1.2: Trafik yoğunluğu tespiti tasarım aşamaları.

2. LİTERATÜR İNCELEMESİ

Trafik yoğunluğu tespiti için literatürde bahsedilen sensörler ve bunların olumlu, olumsuz yönleri bu bölümde yer alacaktır. Son zamanlarda üzerinde çok fazla çalışmanın yer aldığı ve bu çalışmada kullanılacak trafik gürültüsünü oluşturan akustik sinyalin yapısı detaylandırılacaktır. Trafik gürültüsünü sayısal ortama taşıyan mikrofona tekli veya çoklu olmasının avantajları ve dezavantajlarından bahsedilecektir. Daha sonra sayısal ortamdaki akustik ses ile trafik yoğunluğu tespiti için sinyal önileme, öznelik çıkarımı, öznelik indirgeme ve sınıflandırma yöntemlerinden bahsedilecektir.

2.1. Sensör Teknolojisi

İnsan çeşitli duyuları ile dışardan aldığı verileri kullanarak trafiğin yoğun olup olmadığını kestirebilmektedir. Burada en önemli aşamalardan biri dışarıdaki bazı verileri algılamaktır. Hareket eden bir araç çevresine termal, sismik, akustik, elektriksel, manyetik, kimyasal ve optik vb. sinyaller yaymaktadır [20]. Böylece araçlar tarafından oluşturulan verileri farklı sensörlerle algılayarak trafik yoğunluğu seviyesi tespit edilebilir.

2.1.1. Aktif Sensörler

Aktif sensörler, sinyallerini kendileri üretip bu sinyalin dış ortama etkileşimini ölçen sensörlerdir. Sinyallerini kendileri ürettikleri için harici güç kaynağına ihtiyaç duyarlar. Bunların en önemli özelliklerinden biri düşük sinyalleri ölçebilmeleri nedeniyle oldukça hassas ölçüm yapabilmeleridir. Aktif sensörler ürettikleri sinyal türüne göre digital ve analog sinyal çıkışı vermektedirler. Digital sinyal olarak 0 ya da 1 çıkışını vermektedirler. Çıkış sinyali analog olan sensörler ise gerilim veya akım çıkışı verebilirler. Gerilim sinyali olarak genelde 0-5 V arasında bir gerilim vermektedirler. Akım sinyali olarak ise genelde 4-20 mA arası bir çıkış vermektedirler. Trafik yoğunluğu tespitinde kullanılan bazı aktif sensörler;

- Radar

Radar her koşulda trafik yoğunluğunu gösterme kabiliyetine sahiptir. Ancak diğer sensörler ile karşılaştırıldığında kurulumu ve teknik desteği maliyetlidir [21].

- Endüktif Döngü (Inductive Loop)

Gelişmiş ülkelerde Akıllı Ulaşım Sistemlerinde çok yoğunlukta kullanılan bir yöntemdir. Ancak kurulumu ve teknik desteği maliyetli olmasından dolayı çok geniş alanlara kurulamamaktadır. Bu yöntemde yol yüzeyi kazılarak, yüzeyin altına sensörler yerleştirildiği için trafik akışına da etkisi olmaktadır. Kurulumunda ve teknik desteğinde trafik akışına olumsuz etkisi olmaktadır [22], [23]. Yüksek sıcaklık değişikliklerine çok hassastır ve yüksek sıcaklık değişiklikleri performansını olumsuz etkilemektedir.

- Manyetik Duyarlılık

Manyetik duyarlılık, Akıllı Ulaşım Sistemlerinde araç tespiti ve araç hızını ölçmek için kullanılmaktadır [24]. Ancak gürültü ve sıcaklık değişikliklerinde manyetik duyarlılığın hassasiyeti doğru çalışmamaktadır [25].

2.1.2. Pasif Sensörler

Sinyal üretebilmek için dışarıdan harici hiçbir güç kaynağına ihtiyaç duymayan fiziksel ya da kimyasal değerleri istenilen çıkış değişkenine dönüştürebilen sensörlerdir. Bu sensörler çevrelerinden alınan sinyalleri ölçerler.

Pasif sensörlerin ile aktif sensörler karşılaştırıldığında pasif sensörlerin birçok avantajları vardır. Bunlar;

- Veri toplama işlemini hareket eden nesnelere engel olmadan yapar.
- Pasif sensörlerin kurulumu ve teknik desteği daha ucuz maliyetlidir.

Böylece Akıllı Ulaşım Sistemlerinde araç tespiti, araç hızı ve trafik yoğunluğu tespiti işlemlerinde kullanılması uygundur [26], [27].

- Görüntü İşleme

Akıllı Ulaşım Sistemleri için görüntü işleme çok doğal yöntem olarak görünmektedir. Ancak kamera görüntüsü alınarak görüntü işleme ile araç takip, trafik yoğunluğu tespitlerine yönelik yapılan çalışmalarda değişik ışık ortamlarından ve çevresel perdelemelerden dolayı nesne belirlemede yetersiz kalındığı gözlemlenmiştir. Görüntü işleme alanında teknolojik olarak çok ileri düzeylere gelmiş olmasına rağmen bu problemler tam kararlı bir şekilde çözümlenememiştir. Belli bir zamandan sonra araç ile sensör arasına ağaçlar, binalar girdiğinden dolayı Akıllı Ulaşım Sistemlerinde hedeflenen başarı azalmaktadır. Aynı zamanda görüntü işleme çok fazla hesaplama ve işlem gerektiren fonksiyonlara sahip olduğundan çok nitelikli ekipmanların kullanılması gerekliliği maliyeti yükseltmektedir. Bu nedenle geniş çaplı uygulanabilirliği çok mümkün olmamaktadır [5]-[9], [28].

Video kamera ile veri toplamak diğer görüntü işleme yöntemlerinden daha düşük maliyettedir. Ancak sisli havalarda veya geceleri kullanmak için uygun değildir [26].

Uydu, geniş alanda uygulanması ve trafik görüntüleme sisteminin geniş alanları gözlemlemesi için uygundur. Ancak maliyetinin yüksek olması, yeryüzü görüntülemesinin düşük çözünürlükte olması ve bulutlu havalarda görüntünün alınamaması gibi dezavantajlar yaygın kullanılmasına engel olmuştur.

Termal kızılötesi karanlık durumda bile kullanılmaktadır. Ancak gürültü durumunda bazı trafik yoğunluğu tespit uygulamaları çok zor iş olabilir [28].

- Akustik Sinyal İşleme

Akustik sinyaller mikrofon ile ölçülebilmektedir. Mikrofonlar yapısal özelliklerine göre dinamik, piezoelektrik ve kapasitif olmak üzere üç temel tipten oluşmaktadırlar [29]. Uygulamaya uygun mikrofon seçmek için frekans cevabı, yön cevabı ve hassasiyeti gibi önemli özelliklerine dikkat edilmelidir.

2.2. Akustik Sinyalin Yapısı

Araçlar çeşitli akustik gürültüler üretmektedir. Bunlar aracın hızına, yüküne, mekanik durumuna ve aynı zamanda çevre şartlarına bağlıdır [21]. Bu çevre şartları rüzgâr, rüzgârın yönü, yağış, hava sıcaklığı, aracın temas ettiği yüzeyin türü ve yaya

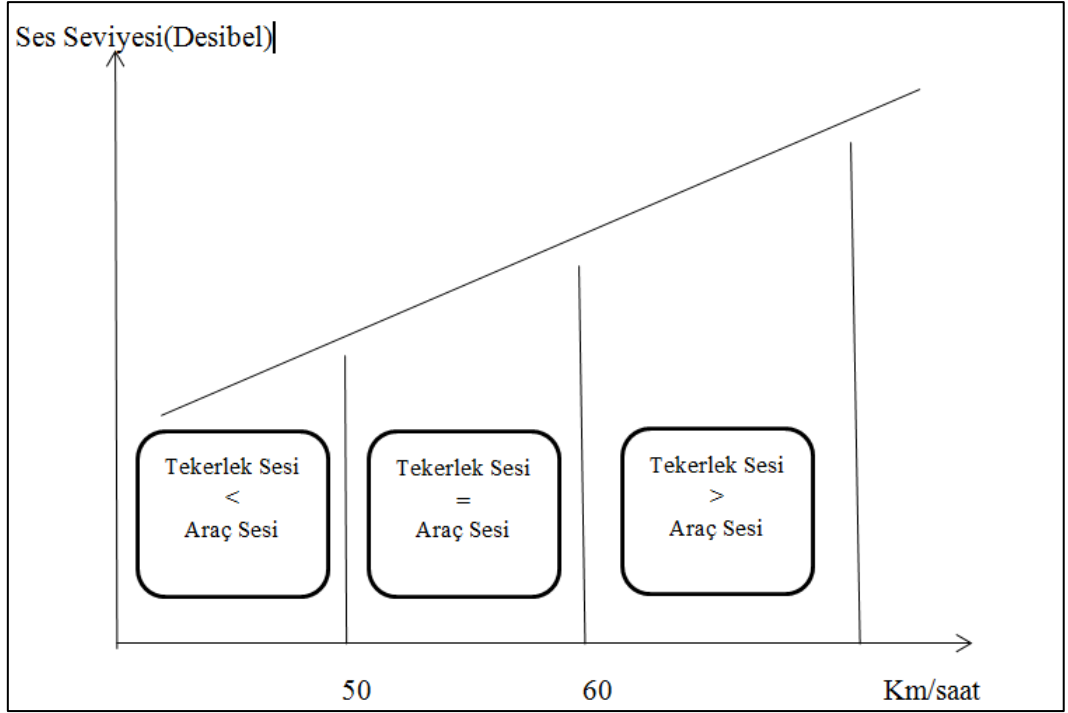
kullanımının sıklığı gibi unsurlardır. Aracın ürettiği ses sinyali aşağıdaki gibi kategorize edilebilir.

2.2.1. Motor Sesi

Motor sesi aracın hızından ve hızlanmasından dolayı değişiklik göstermektedir. Araç durmasına rağmen, rölantide çalışmasında belli bir motor sesi yaymaktadır. Bu durum genelde çok sıkışık trafik yoğunluğu durumlarında gözlemlenmektedir. Sonuç olarak duran araç, orta hızda hareket halindeki araç ve hızlı hareket halindeki araç farklı motor sesleri üretmektedir [3], [34].

2.2.2. Tekerlek Sesi

Tekerlek sesi, araç tekerleğinin temas ettiği yüzey ile etkileşimi sonucu meydana gelmektedir. Tekerlek sesi, hava gürültüsü ve titreşim gürültüsü olmak üzere iki birleşenden oluşmaktadır. Hava gürültüsü tekerleğin lastikleri arasına havanın sıkışması sonucu oluşmaktadır. Hava gürültüsü 1 kHz ile 3 kHz aralığında baskındır. Titreşim gürültüsü, tekerlek ile yüzeyin etkileşimi ile oluşmaktadır. Titreşim gürültüsü, 100 Hz ile 1000 Hz aralığında baskındır. Şekil 2.1'de gösterildiği gibi tekerlek sesi, araç hızı 50 km/s ve üstü olduğu zaman toplam sinyal içinde daha baskın olmaktadır [3], [35]. Bu bilgiler eşliğinde tekerlek sesi araç yoğunluğu sınıflandırmasında kullanılacak bilgidir. Bu sesin oluşumunda tekerleğin yapısı, yüzeyin yapısı, yüzeyin ıslak veya kuru olması gibi unsurlar etkilidir. En basit örnek; yüzey ıslak olduğu zaman tekerlekle ile yüzeyin etkileşiminden çıkan sesi kulağımızla daha net duyarız.



Şekil 2.1: Hız-Ses seviyesi.

2.2.3. Hava Türbülansı Sesi

Araç orta hızda ve çok hızlı hareket ettiği zaman meydana gelir. Aracın dış kısmının hava ile teması sonucu oluşmaktadır. Araç hızlandıkça hava türbülans sesi şiddeti artmaktadır [36]. En basit örnek; otoban kenarında hızlı geçen araçların vız vız diye çıkardıkları hava türbülans sesini duyarız. Hava türbülans sesi aracın aerodinamik yapısına, aracın hızına, rüzgar hızına ve rüzgarın yönüne bağlıdır [3].

2.2.4. Egzoz Sesi

Egzoz sesi araçtaki egzoz aparatından çıkmaktadır. Bu egzoz borusu ile motor yanma bölgesine bağlıdır. Motor sesine benzemez ve aracın yükü arttıkça egzoz sesi de büyür [1]. Egzoz sesi güç spektrumunda düşük frekansa sahiptir [3].

2.2.5. Korna Sesi

Korna kullanımı Güney Asya, Hindistan gibi ülkelerde alışkanlık olmuştur. Trafik akışının olduğu yerlerde sürücüler genelde korna kullanmazlar. Ancak trafiğin yoğun olduğu bölgelerde korna sesini sık duyarız. Yaya kullanımının sık olduğu bölgelerde de korna sesi sık duyulabilir [1].

2.3. Akustik Sensör ve Kullanım Şekilleri

Akustik sinyaller mikrofon ile ölçülebilmektedir. Mikrofonlar yapısal özelliklerine göre dinamik, piezoelektrik ve kapasitif olmak üzere üç temel tipten oluşmaktadırlar [29].


Sistem tek veya birden fazla akustik sensör içerebilir. Birden fazla sensör içeren sistemlerde sensör dizisi veya dağıtık sensör ağları kullanılabilir [1], [12], [13]. Bunların kendilerine göre avantajları ve dezavantajları Tablo 2.1’de gösterilmiştir.

Tablo 2.1: Tekli-Çoklu sensör karşılaştırılması.

	Avantajlar	Dezavantajlar
Tekli Sensör	<ol style="list-style-type: none">1. Maliyeti düşük2. Giriş sinyali kompleks değil3. Düşük güç tüketimi4. Az yer ihtiyacı	<ol style="list-style-type: none">1. Sinyal kaynağının yerini tam belirleyemez.2. Tek sensör hata yaptığında destekleyecek bir ek bilginin olmaması
Çoklu Sensör	<ol style="list-style-type: none">1. Sinyal kaynağının yerini tam belirleyebilir.2. Doğruluk oranının yüksek olması	<ol style="list-style-type: none">1. Giriş sinyali biraz kompleks2. Güç tüketimi biraz fazla3. Maliyeti fazla

2.4. Ön İşleme

Ses sinyali üzerinde öznitelik çıkarımı için gerekli vurgulamaları yapar. Gürültülerin arındırılması, yüksek frekansların daha baskın hale getirilmesi, FFT ve katsayıların elde edilmesi için daha uygun zemin hazırlar. Rüzgarın sensöre etkisi ile oluşan gürültü, çevreden gelen istenmeyen gürültü veya sensör ile sistem arasında oluşabilecek gürültülerdir. Bu istenmeyen sinyallerin durması sinyal üzerinde yapılacak işlemlerin başarısını azaltmaktadır [30]. Bundan dolayı ses sinyalinin gürültülerden arındırılması ve yüksek frekansların daha baskın hale getirilmesi için sinyal ilk olarak ön işleme fazından geçirilir. Ön işleme Şekil 2.2’de gösterildiği gibi vurgulama (pre-emphasis), çerçeveleme (framing) ve pencereleme (windowing) olmak üzere üç aşamadan oluşmaktadır.



Şekil 2.2: Akustik sinyalin ön işleme aşamaları.

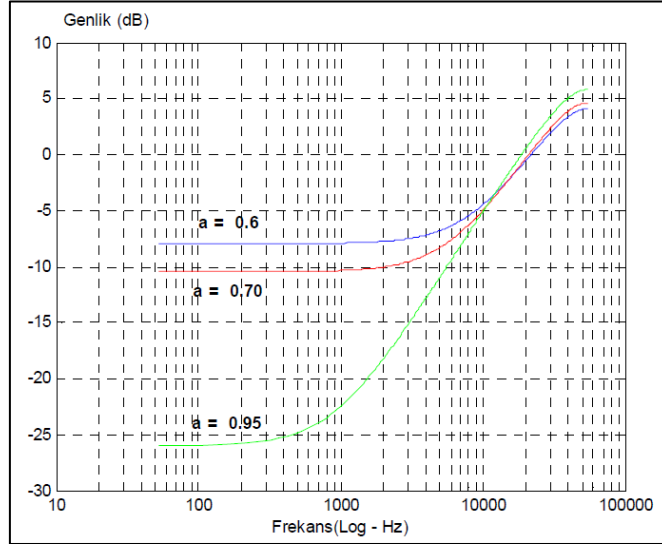
2.4.1. Ön Vurgulama

Yüksek frekanslı bölgelerde ses üretim sisteminin yapısından kaynaklanan bir sönümlenme oluşur. Bu nedenle ön vurgulama olarak isimlendirilen ve yüksek frekanslı bölgeleri güçlendiren bir filtreleme uygulanır [47]. Ön vurgulamanın amacı ani düşüşlerin olduğu sesli bölgelerin spektrumunu dengelemektir. Bu nedenle örneklenmiş ses sinyali birinci dereceden FIR (Sonlu Dürtü Yanıtı) bir filtreden geçirilerek sinyal spektral olarak düzlenir. Bu filtreye önvurgu (pre-emphasis) filtresi denir. Yaygın olarak kullanılan ön vurgu filtresinin fark denklemi Eşitlik 2.1’de gösterilmiştir [48].

$$y[n] = x[n] - a \cdot x[n - 1], \quad a \approx (0,95 - 0,97) \quad (2.1)$$

Bu filtreye ait transfer fonksiyonu Eşitlik 2.2'deki gibidir.

$$H(z) = 1 - az^{-1} \quad 0.95 \leq a \leq 0.97 \quad (2.2)$$




Şekil 2.3: Önvurgu filtresi frekans tepkisi.

2.4.2. Çerçeveleme

Ses işareti, parametrelerin sabit kaldığı varsayıldığı, çerçeve olarak adlandırılan küçük parçalara ayrılmalıdır. Çünkü tüm işaret boyunca FFT (Fast Fourier Transform) hesaplanırsa, farklı fonemlere ait spektral bilgilerin tutulmasında kayıplar oluşur. Konuşma tanımlama çalışmalarında tüm işaretin FFT'sini almak yerine çerçevenin FFT'si hesaplanır. Çerçeve uzunluğu 30-50 ms arasında değişir. Bu aralıkta ses oldukça sabit akustik karakteristik gösterir. Her bir çerçeveye örtüşme uygulanır. Çerçevelerin örtüşme oranı, çerçeve uzunluğunun %30'u ile %75'i arasında alınır [49]. Örtüşmeli çerçevelerin kullanılmasının nedeni, çerçeveden çerçeveye geçişlerde oluşacak süreksizlik etkilerini en aza indirmektir. Örtüşme uygulanması ile çerçeve sonundaki işaretin önemlerini kaybetmemesi sağlanır.

Ses örneğinin ortalaması çıkarıldıktan sonra, ses değişimlerine karşı sabit kabul edilebilecek parçalar şu şekilde ifade edilir. Ses işareti M örnek uzunluğunda ses parçalarına bölünür. İlk çerçeve M örnekten oluşurken sonraki çerçeve ilk

çerçveden K örnek sonra başlar ve böylece M-K örnek örtüşür. Şekil 2.4'te bir konuşma işareti üzerinde çerçeveleme işlemi görülmektedir.



Şekil 2.4: Ses işaretinin çerçvelere bölünmesi.

2.4.3. Pencereleme

Pencereleme, sinyalin zaman bölgesinde bir pencere fonksiyonu $w(n)$ ile çarpılması işlemidir. Pencerelemenin amacı çerçeveleme işlemi sonucunda oluşan spektral etkilerin azaltılmasıdır. Pencereleme ile çerçvelerde süreksizliğin önüne geçilir. Bu sayede sesin orta bölgeleri güçlendirilirken kenar bölgeleri zayıflatılır.

Yaygın olarak kullanılan Hamming, Hanning, Blackman, Gauss, dikdörtgen ve üçgen pencereleme fonksiyonlarının matematiksel ifadeleri aşağıdaki gibidir [9].

Hamming :

$$w[k + 1] = 0.54 - 0.46 \cos\left(2\pi \frac{k}{N-1}\right) \quad k = 0, \dots, N-1 \quad (2.3)$$

Hanning :

$$w[k + 1] = 0.5 \left(1 - \cos\left(2\pi \frac{k}{N-1}\right)\right) \quad k = 0, \dots, N-1 \quad (2.4)$$

Gauss :

$$w[k + 1] = e^{-\frac{1}{2} \left(\alpha \frac{k - \frac{N}{2}}{\frac{N}{2}} \right)^2} \quad 0 \leq k \leq N \quad ve \quad \alpha \geq 2 \quad (2.5)$$

Dikdörtgen :

$$w[k + 1] = 1 \quad k = 0, \dots, N - 1 \quad (2.6)$$

Üçgen : N tek için;

$$w[k] = \begin{cases} \frac{2k - 1}{N} & 1 \leq k \leq \frac{N}{2} \\ \frac{2(N - k + 1)}{N} & \frac{N}{2} + 1 \leq k \leq N \end{cases} \quad (2.7)$$

Ses işaretinin spektral analizinde genellikle Eşitlik 2.3'te bağıntısı verilen hamming penceresi tercih edilir. Eşitlik 2.3'te verilen bağıntıda N pencerenin uzunluğunu belirler. Pencere uzunluğu sesin perde periyodu göz önüne alınarak seçilmeli ve yapılan kısa zamanlı spektral analizde harmonik yapı net olarak elde edilmelidir. N çok büyük seçilmesi durumunda (birkaç perde periyodu boyunca) sinyalin bu aralıktaki spektrumu yumuşatılacağından (smoothing, averaging) spektrumdaki değişimler izlenemeyecektir. N küçük seçilmesi halinde ise harmonikler net olarak elde edilmeyebilir. N pratik sistemlerde 10-50 ms'ye karşılık gelecek şekilde seçilir.

2.5. Öznitelik Çıkarımı

Akustik sinyalin özellikleri algısal ve fiziksel olmak üzere ikiye ayrılmaktadır. Ses tınısı, ses yüksekliği, ses parlaklığı ve ses ekortu gibi özellikler algısal özelliklerdir. Spektrum, enerji gibi özellikler fiziksel özelliklerdir. Fiziksel özellikler kaydedilmiş ses verisinden hesaplanabilir. Burada önemli olan konu insan algısını tanımlayabilmek için, uygun olan fiziksel özellikleri bulabilmektir. Öznitelik çıkarım algoritmaları fizikselden algısal dönüşümü bulmaya çalışırlar.

Öznitelik çıkarımın amacı, yüksek bilgi içeren bir pakete sinyal işleme algoritmaları uygulanarak, paketi onunla ilişkili, onu temsil eden küçük veri setine dönüştürmektir. Burada önemli olan nokta gereksiz bilgiler hariç önemli olan bilgilerin korunmasıdır.

Öznitelik çıkarımı algoritmaları giriş verisinin karakteristiğini göstermek için sınıflandırma yapmada en etkili, verimli bilgilerin toplanmasını sağlar. İyi bir öznitelik çıkarım algoritması sınıflandırma algoritmasının performansını geliştirmek amacıyla her bir sınıf için sinyal karakteristiklerini kalıtsal arttıran ve tespit eden verilerin miktarını azaltabilir. Trafik yoğunluğu durumunun doğru tespiti için en zor fakat en önemli aşama deneysel olarak en uygun özniteliklerin seçilmesidir [31].

Konuşma tanıma, müzik tanıma, araç tanıma, araç hızı tespiti gibi günümüz çalışmalarının çoğunda öznitelik çıkarım tekniği çok yoğunlukta kullanılmıştır. İyi öznitelik çıkarma algoritması aynı sınıfı temsil edenlerin bir alanda birleşmesini ve diğer sınıflar ile arasında mesafe olmasını sağlar. Öznitelik çıkarımı zaman uzayı, frekans uzayı ve zaman-frekans uzayı olmak üzere üç gruba ayrılmaktadır [31]. Frekans uzayında MFCC öznitelik çıkartma yöntemi insan kulağı yapısını simüle edecek şekilde formüle edilmiştir.

Akustik öznitelik çıkarımı için mevcut olan algoritmalar zaman, frekans ve zaman-frekans uzayı temellidir [32].

2.5.1. Zaman Uzayı

Zaman uzayı çok düşük hesaplama gerektirmektedir. Ancak öznitelikler gürültü ve rüzgâr etkileri ile engellenmektedir.

Chen, karayollarındaki araçların ürettiği ses sinyalini kullanarak araçların yoğunluğu ve hızı vb. bilgilerin elde edilmesini amaçlamıştır. Araç sesinin, farklı yerlere konan iki mikrofona ulaşma zamanı farklı olacağından, iki mikrofondan elde edilen ses verileri sayısallaştırıldıktan sonra çapraz korelasyon (cross-correlation) algoritmasında işlenmektedir. Araç iki mikrofonun ortasına geldiğinde maksimum korelasyon oluşacağından dolayı geçen araç sayısı, hızı ölçülebilmektedir [12].

Barbagli, kablosuz sensör haberleşme ağı ile gerçek zamanlı araç trafik yoğunluğu durumunu görüntülemeyi hedeflemiştir. Ana düğüm ve sensör düğümlerinden oluşan bir ağ kurmuştur. Ana düğüm, iki mikrofonlu yapısı ile yol

kenarındaki tüm ses verisini alır, arka plandaki gürültünün ve karşı şeritten gelen gürültünün yok edilmesi için yüksek geçiren filtre uygulamış, sonra çapraz-korelasyon yöntemi kullanarak geçen araçları tespit etmiştir. Sensor düğümleri ses verisinin zaman uzayında enerji dağılımına bakarak trafik yoğunluk bilgisini ana düğüme iletir, bu sayede ana düğümde oluşan trafik yoğunluk bilgisini müşteri veya kullanıcı için sunucuya iletir [13].

2.5.2. Frekans Uzayı

Tyagi, karayolunda geçen araçların oluşturduğu gürültü (tekerlek lastiklerinin oluşturduğu gürültü, motor gürültüsü, araç rölanti gürültüsü, ara sıra korna gürültüsü ve hava türbülansı vb.) sinyallerini kullanarak araç trafik yoğunluğunun kestirimini hedef almıştır. Sınıflandırmada, MFCC temelli oluşan akustik sinyalin özniteliklerini kullanmıştır [1].

Bhave, çalışmasında taşıtların akustik özelliklerini incelemiştir. Taşıtları iki tekerlekli, üç tekerlekli ve ağır taşıt şeklinde sınıflandırmıştır. Bhave'in bu çalışmasında LPC analiz ile hesaplanan öznitelikler ile MFCC ile hesaplanan özniteliklerin doğrulukları karşılaştırılmaktadır. MFCC temelli öznitelik çıkarımı ile elde edilen doğruluğu %68-96 arasında, LPC temelli öznitelik çıkarım yöntemi ile elde edilen doğruluğu ise %50-92 arasında bulmuştur [14].

Sen, araç korna sesini baz alarak araç hızlarının tespitini sağlamıştır. Araç hızı, korna sayısı, korna süresi ve gürültü seviyesi gibi metriklere göre yol trafik yoğunluğu durumunu serbest-akış ve sıkışık olmak üzere iki durumda sınıflandırmayı hedeflemiştir. Korna sesinin düzensiz yol durumlarının karakteristik özelliği olduğunu düşünerek, hareket halindeki aracın hızını iki mikrofon arasında kornaya bastığı zaman, korna frekansının Doppler kaymasından (Doppler Shift) kestirebileceğini varsaymıştır. Araç trafik yoğunluğu durumunu serbest-akış ve sıkışık olmak üzere %75-100 doğruluk ile tespit etmiştir [33].

Rajendra, farklı trafik yoğunluğu durumları farklı çevresel gürültü oluşturur varsayımı ile trafik yoğunluğu durumunu sıkışık, sabit hız, hızlı ve boş olmak üzere dört farklı sınıfa ayırmayı hedeflemiştir. Topladıkları gürültü verilerini trafik durumu türüne göre 4-5 saniyelik bölümlere ayırmıştır. Her bölüm FFT işleminden geçirilerek zaman uzayından frekans uzayına geçiş yapılmıştır. 100 Hz frekans

genişliğinin üstündekilerin ortalama genliklerini hesaplamıştır. Bu genlik-frekans ilişkisini sınıflandırıcıda giriş olarak kullanmıştır. Bu durumda yaklaşık %92 doğruluk oranı elde etmiştir [15].

Joshi, çalışmasında trafik yoğunluk durumu (sıkışık, orta-akış, hızlı-akış) sınıflandırması için akustik temelli bir yöntem ileri sürmüşlerdir. Yol kenarındaki ses sinyalinde elde edilen MFCC bilgisi bazlı sınıflandırma ile korna sesi bazlı sınıflandırmayı birleştirmişlerdir. MFCC temelli sınıflandırma için Tyagi'nin çalışmasındaki MFCC yöntemi pencere boyutu 100 ms ve kaydırma boyutu 50 ms olacak şekilde aynen uygulamıştır. Eğitim setini oluştururken toplam zaman aralığı $T_{acc} = 10$ saniye süresine göre sınıflandırmayı belirlemiştir. Bu süre içinde toplam korna sesine sahip pencerelerin sayısına göre sınıflandırma yapmıştır. Toplam ses içinde, korna sesini tespit için frekans spektrumunun kare genlikli değerlerin varyasyonu yöntemini kullanmıştır. Daha önce yapılan çalışmalarda korna tespitinde kullanılan ortalama tepe genliği yöntemi ile frekans spektrumunun kare genlikli değerlerin varyasyonu yöntemini karşılaştırmışlardır. Varyasyon yaklaşımının daha iyi performans verdiğini gözlemlemiştir. 10 saniyelik ses verisindeki korna bilgisi ile yapılan sınıflandırmada çok düşük oranda doğruluk elde etmiştir. MFCC bilgisi ile sınıflandırma ses verisi 10 saniye olsa bile iyi doğruluk oranı elde etmiştir. Bu sonuçlardan dolayı birleşik sınıflandırmanın doğruluk oranının düşük olmasının nedeninin korna bilgisi kullanılarak elde edilen sınıflandırma olduğunu düşünmüştür. Bundan dolayı korna yüzdesine göre trafik yoğunluğu durumlarının olasılık yoğunluk fonksiyonuna (PDF - Probability Density Function) bakarak korna yüzdesi %40 altında olduğunda trafik yoğunluğu sınıflarının çok kesiştiklerini, %40 üstünde olduğunda trafik yoğunluğu sınıflarının çok az kesiştiğini gözlemlemiştir. Sonrasında korna yüzdesine göre birleşik sınıflandırmada değişikliğe gitmiştir. Sonuç olarak $T_{acc} = 10, 20, 30$ saniyeler için MFCC bilgisi bazlı sınıflandırmada %86-94 arası doğruluk, korna bazlı sınıflandırmada %67-79 arası doğruluk ve birleşik sınıflandırmada %89-96 arası doğruluk elde etmiştir [16].

Borkar, karayolları kenarına yerleştirilen tek bir mikrofondan elde edilen kümülatif akustik sinyaldeki mevcut bilgilere dayanarak araç trafik yoğunluğu durumu tahmini problemini değerlendirmektedir. Borkar'ın bu çalışmasında MFCC yöntemi kullanılarak kümülatif akustik sinyalin kısa süreli spektral zarf öznitelikleri çıkarıldı. Trafik yoğunluk durumunu az (40 km/s ve üstü) , orta (20-40 km/s) ve çok (0-20 km/s) gibi modellemek için sınıflandırıcıya spektral zarf öznitelikleri

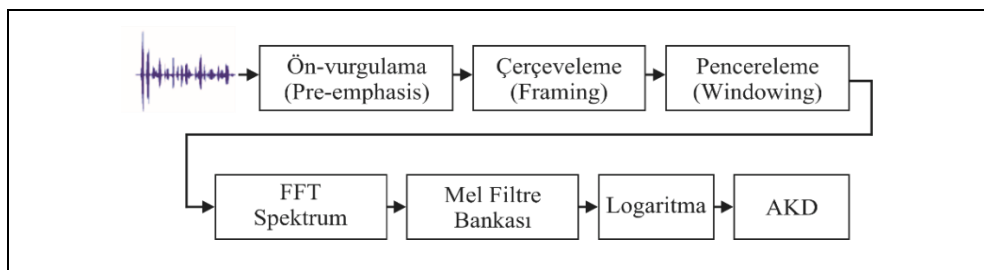
girdi olarak verilmiştir. Bu çalışma, kurulumu ve teknik desteği çok düşük olan basit bir mikrofon ile yol kenarında toplanan akustik sinyallerin kabul edilebilir doğruluk ile araç hızını ve trafik yoğunluk durumunu tahmin etmede kullanılabilir olduğunu göstermiştir [2].

- Mel-Ölçekli Kepstrum Katsayıları

MFCC özniteliği insan kulağının frekans algılamasını model alan ve FFT tabanlı olarak hesaplanan bir sayısal teknik analizdir [37]. Ayrıca MFCC değişimlerden, ses dalga yapısından çok daha az etkilenir.

MFCC işleminin aşamaları Şekil 2.5'te gösterilmektedir. MFCC Katsayıları elde edilmesinde ilk aşama olarak, ses işareti, N örnekten oluşan çerçevelere ayrılır. İlk çerçeveden sonra takip eden çerçeveler M örnekten itibaren alınır ($M < N$). Çerçevedeki işaret süreksizliklerini en aza indirmek için her bir çerçeve pencereleme işlemine tabi tutulur. Zaman alanındaki her bir çerçeve hızlı Fourier dönüşümü ile N örnekten oluşan frekans alanına çevrilir. Frekans alanındaki işaret, Mel frekans ölçeğine göre dizilmiş süzgeç dizilerinden geçirilir ve logaritması alınır. Son aşamada, ayrık kosinüs dönüşümü kullanılarak zaman alanına geri dönülür. Son aşamada elde edilen katsayılara mel frekans kepsrum katsayıları denir.

Mel-frekans kepsrum katsayıları, algı temelli sesi temsil eden katsayılardır. Fourier Dönüşümü veya Ayrık Kosinüs Dönüşümü'nden türetilir. FFT/DCT ve MFCC arasındaki temel fark MFCC'de frekans bantları logaritmik olarak (Mel ölçüsünde) yerleşmiştir ve bu da insan ses sisteminin yanıtını bantları doğrusal olarak yerleşen FFT veya DCT'ye göre daha da yaklaştırır.



Şekil 2.5 : MFCC öznitelik çıkarım aşamaları.

- Hızlı Fourier Dönüşümü

MFCC elde edilmesinde, pencereden geçirilen işaretin genlik spektrumu FFT ile hesaplanır. FFT ile N örnekten oluşan zaman alanındaki her bir çerçeve, frekans alanına çevrilir. FFT, ayrık Fourier dönüşümünden üretilmiştir. Bir çerçevenin $\{x_0, x_1, \dots, x_{N-1}\}$, ayrık Fourier dönüşümü Eşitlik 2.8'de tanımlanmıştır.

$$X[k] = \sum_{n=0}^{N-1} x_n \cdot e^{-\frac{2\pi jkn}{N}} \quad k = 0, 1, 2, \dots, N-1 \quad (2.8)$$

Burada genellikle $X[k]$ 'lar kompleks sayılardır. Sonuç olarak elde edilen dizi $\{X[k]\}$: sıfır frekansı $k=0$ 'a karşılık gelip, pozitif frekanslar ($0 < f < f_s/2$), $1 \leq k \leq (\frac{N}{2}) - 1$ değerlerine karşılık gelirken, negatif frekanslar ($-f_s/2 < f < 0$), $(\frac{N}{2}) + 1 \leq k \leq N-1$ 'e karşılık gelir. Burada, f_s örnekleme frekansdır [52].

Bir konuşma parçasının FFT'sinin k. harmonik bileşeni $X[k] = X_{re}[k] + jX_{im}[k]$ şeklinde bir kompleks sayı olarak ifade edilsin. Bu ifade kutupsal olarak Eşitlik 2.9'daki gibi tanımlanır.

$$X[k] = |X[k]|e^{j\angle X[k]} \quad (2.9)$$

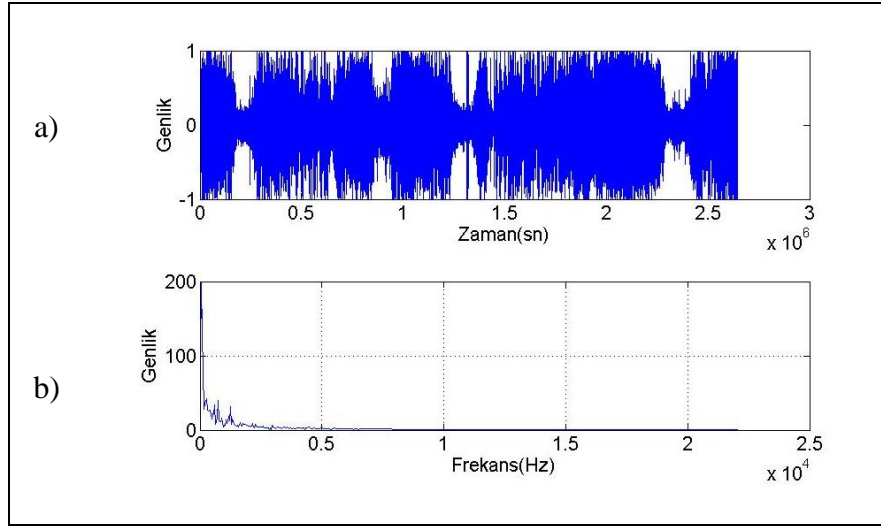
$$|X[k]| = \sqrt{|X_{re}[k]|^2 + |X_{im}[k]|^2} \quad (2.10)$$

$$\angle X[k] = \tan^{-1}\left(\frac{X_{im}[k]}{X_{re}[k]}\right) \quad (2.11)$$

Burada $|X[k]|$ k. harmonik bileşene ait genlik, $\angle X[k]$ ise fazı olarak adlandırılır. Ses gibi gerçel işaretler için genlik spektrumu $N/2$ ile simetriktir. Ses analizinde faz spektrumu genellikle ihmal edilir. Çünkü faz spektrumu ses ile ilgili önemli bilgi taşımamaktadır [38].

Bir işaretin FFT'si hesaplanırken işaretin uzunluğu 2^M $M \in \mathbb{N}_+$ şeklinde başka bir değişle 2'nin kuvvetleri şeklinde olmalıdır. Örneğin işaret 400 örnekten oluşuyorsa işaretin uzunluğu 512 olana kadar işarete sıfır eklenir ve bu şekilde FFT'si hesaplanır. İşaretin başına veya sonuna sıfır eklenmesi FFT sonucunu değiştirmez [39].

Eşitlik 2.8 bağıntısıyla gerçekleştirilen ayrık Fourier dönüşümü karmaşık ses sinyalini ayrıştırarak hangi frekansta ne şiddette bir titreşim olduğunu hesaplar. Bu dönüşüm için genellikle hızlı bir algoritmanın uygulandığı FFT yöntemi tercih edilir. Şekil 2.6’da bir ses sinyali ve FFT sonucu elde edilen frekans bileşenleri gösterilmektedir.

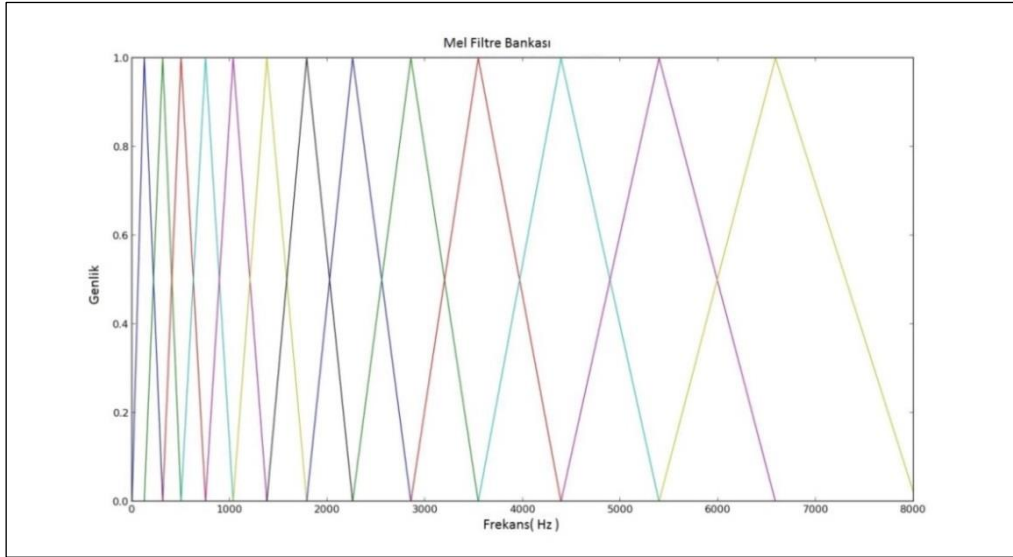


Şekil 2.6: Ses sinyali. a) Zaman uzayı, b) Frekans uzayı.

- Mel-Filtre Bankası

Mel-frekansı, iç kulak içinde gerçekleşen frekans analizine dayanmaktadır. Yapılan araştırmalar sonucunda insanın frekans içeriklerini 1 kHz’e kadar lineer 1 kHz’in üzerinde ise logaritmik olarak algıladığı görülmüştür [40]. Bu model Davis ve Mermelstein tarafından formüle edilmiştir [41].


Mel ölçeği için eşit aralıklı bir filtre bankası kullanılmaktadır. Mel filtre bankasının amacı duyma mekanizmasının kritik bant filtrelerinin simülasyonunu yapmaktır. Bu filtre bankası Şekil 2.7’de gösterildiği gibi üçgen bant geçiren filtre cevabı olan ve bant genişliği sabit olan filtreler ile sağlanır [42]. Bu işlem ile lineer frekans ölçeği, mel ölçeğine dönüştürülmüş olur.



Şekil 2.7: Mel filtre bankası.

Mel frekansı, Eşitlik 2.12'deki formül ile hesaplanır. Gerçek frekansın birimi Hertz, Mel frekansının birimi ise Mel'dir ve arasındaki bağıntı Şekil 2.8'de grafiksel olarak gösterilmiştir [38].

$$mel(f) = 2595 \cdot \left[\log_{10} \left(1 + \frac{f}{700} \right) \right] \quad (2.12)$$



Şekil 2.8: Frekans ve Mel-frekans arasındaki bağıntı.

- Logaritma Hesaplanması

Spektrumun logaritmasının alınmasının nedeni ses işaretinin çarpma bileşenlerinin toplama bileşenlerine dönüştürülmesidir. Ses işareti spektrumu, süzgeç dizisinden geçirildikten sonra logaritması alınır. Ses işareti Eşitlik 2.13 ile ifade edilebilir.

$$|S(e^{j\omega})| = |X(e^{j\omega})| |F(e^{j\omega})| \quad (2.13)$$

Burada S, X, F sırası ile ses işareti, kaynak ve süzgece karşılık gelmektedir. Kaynak, üretilen ve değişime uğramamış ses işaretini temsil eder. Süzgeç ise ses yolu olarak ifade edilen sesin izlediği yola karşılık gelmektedir [50]. Ses yolunun etkisini kaynaktan ayırmak için logaritma kullanılır. Logaritma alınarak, konuşma işaretinin bileşenlerinin çarpımı, bileşenlerin toplamına Eşitlik 2.14'teki gibi dönüştürülür.

$$\log|S(e^{j\omega})| = \log|X(e^{j\omega})| + \log|F(e^{j\omega})| \quad (2.14)$$

Logaritmik spektrum farklı frekanslara sahip bileşenlerin bileşimi olarak düşünülebilir. Daha sonra bu iki bileşene ters Fourier dönüşümü uygulanarak hızlı ve yavaş değişen bileşenler hakkında bilgi sahibi olunabilir.

- Ayrık Kosinüs Dönüşümü

MFCC elde edilmesinde en son olarak kepstrum katsayıları hesaplanır. Kepstral gösterimi ile kayıt ve iletim ortamından dolayı oluşan spektral şekil değişimleri kaldırılır. Ayrıca kepstral katsayılar, yüksek derecede istatistiksel bağımsızlık gösterip genlik spektrum gösteriminden daha yüksek tanıma oranı verirler. Gerçek kepstrum, logaritmik genlik spektrumunun ters Fourier dönüşümü olarak tanımlanıp, gerçek işaretler için kosinüs dönüşümü kullanılarak hesaplanır. Mel-frekansı kepstrum katsayıları MFCC(i), süzgeç çıkışlarından Eşitlik 2.15'teki gibi hesaplanır [48].

$$MFCC(i) = \frac{1}{FS} \sum_{l=1}^{FS} mfb(l) \cdot \cos \left[i \left(l - \frac{1}{2} \right) \frac{\pi}{FS} \right] \quad i = 1, \dots, FS - 1 \quad (2.15)$$

Burada FS , süzgeç sayısı olarak tanımlanmaktadır.

2.5.3. Zaman - Frekans Uzayı

Kato, hareket halindeki araçların seslerini kullanarak trafik yoğunluğu tespitini otomatik olarak yapılabileceğini ileri sürmüştür. Yaklaşımları, gözlemlenen noktadan bir araç geçtiği zaman güç sinyallerindeki zamansal değişikliklerin tanımlanması fikrine dayanmaktadır. Yerel zamansal değişimler küçük periyotlarda güçteki artma ve azalmaları tanımlamaktadır. Bu tür özellikleri çıkarmak için, dalgacık dönüşümü (wavelet transformation) kullanılarak güç sinyalinin her bir çerçeve için zaman-frekans analizini gerçekleştirmiştir. Hareket eden aracı algılamak için önişlem-dalgacık dönüşümü-eşik değeri işlemlerini sırasıyla uygulamıştır. Belirlediği yöntem ile bir aracın önünde ve arkasında iki saniyelik mesafede herhangi bir araç olmadığı zaman %95 doğruluk, iki saniyelik mesafede başka araç olduğunda %96, karşı şeritte birbirleri ile çakışmadıkları zaman %96, karşı şeritte ve birbirleri ile çakıştıkları zaman %78 gibi doğruluklar elde etmiştir. Toplamda ortalama olarak %94 doğruluk elde etmiştir. Hata oranını düşürmek için, frekans aralığının farklı kullanılmasının etkili olacağını iddia etmiştir [17].

2.6. Öznitelik İndirgeme

Ses sinyalinden elde edilen özniteliklerden bazıları gereksiz olduğu gibi öznitelik miktarı çok fazla olabilmektedir. Gereksiz veri ve verinin çok fazla olması işlem performansını etkilemektedir. Bundan dolayı elde edilen özniteliklerden, kendisini temsil edecek daha az sayıda özneliğin elde edilmesine öznitelik seçimi veya boyut indirgeme denmektedir. ‘Temel Bileşenler Analizi (PCA)’, ‘Doğrusal Ayırışım Analizi (Fisher-LDA)’ gibi yöntemler verilerde boyut indirgeme için kullanılmaktadır.

2.6.1. Temel Bileşenler Analizi

Temel Bileşenler Analizi bir değişkenler kümesinin varyans-kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri vasıtasıyla açıklayarak, boyut indirgemelerini ve yorumlanmasını sağlayan, çok değişkenli bir istatistik yöntemidir. Bu yöntemde p adet değişken; doğrusal, ortogonal ve birbirinden bağımsız olma özelliklerini taşıyan k ($k \leq p$) tane yeni değişkene dönüştürülmektedir. Dönüştürülen k adet değişken, p adet değişkenin açıkladığının tümünü açıklayabilmekte, başka bir deyişle p adet değişkeni temsil edebilmektedir [43], [53]. Temel Bileşenler Analizinde yapılan işlemler;

- Veriler ortalamayla düzgünleştirilir,
- Kovaryans matrisi hesaplanır.
- Eigen Value (özdeğer) ve Eigen Vector (özvektör) hesaplanır.
- İndirgeme için özellik vektörü seçilir ve indirgeme çarpımı yapılır.

2.6.2. Doğrusal Ayrışım Analizi

Doğrusal Ayrışım Analizi sınıf ayırımında kullanılan bilgiyi daha çok koruyarak boyut indirgeme yöntemidir. LDA bilgiler arasındaki varyansı azaltırken, PCA varyansı korumaktadır. Ancak PCA sınıf ayırt ediciliği düşürürken, LDA sınıf ayırt ediciliği korumakta ve yükseltebilmektedir.

2.6.3. Öznitelik Seçimi

Özniteliklerden bazıları, örneğin ait olduğu sınıfla ilgili bilgi içermiyor olabilir. Bu gereksiz özniteliklerin sınıflandırıcıya giriş olarak verilmeleri bir kazanç sağlamayacağı için, sınıflandırma işleminden önce gereksiz özniteliklerin ayıklanmaları gerekir. Sınıf bilgisini içinde barındıran ve sınıflandırıcının işini kolaylaştıran özniteliklerin bulunması için öznitelik seçme ve indirgeme yöntemleri geliştirilmiştir. Öznitelik seçimi için Entropi Ölçütü, Fisher Ölçütü ve Öznitelik vektör histogramı gibi yöntemler kullanılır [53].

- Entropi Ölçütü

Entropi ölçütü özniteliğin içindeki bilgiyi kullanarak seçim yapar. Bu nedenle öznitelik bir dağılım gibi ele alınıp, entropisi hesaplanır. Entropi ölçütü arttıkça sınıfların birbirinden ayırt edilebilmesinin arttığı kabul edilir. Entropi ölçütünü hesaplamak için öznitelik normalleştirilir. Bu sayede tüm değerler sıfırın üstünde olur ve toplam bir eder [44], [53].

M veriye sahip f_t özniteliğinin entropisi aşağıdaki şekilde bulunabilir:

$$E = - \sum_{i=1}^M f_t^*(i) \log(f_t^*(i)) \quad (2.16)$$

$$f_t^*(i) = \frac{f_t(i) + |\min(f_t)|}{\sum_{i=1}^M (f_t(i) + |\min(f_t)|)} \quad (2.17)$$

- Fisher Ölçütü

Doğrusal Ayırma Analizi (LDA) projeksiyon algoritmalarından biridir. Projeksiyon sınıf ayırmasını arttırmak için yapılır, böylece yeni uzayda sınıflandırma işlemi daha kolay yapılabilir. Bu uzayı bulabilmek için iteratif olarak Fisher'in geliştirdiği ölçü artırılmaya çalışılır [53]. Bu ölçü Eşitlik 2.18'deki gibi hesaplanır.

$$d = \frac{\text{sınıflar arası uzaklık}}{\sum \text{sınıf içi dağılım}} \quad (2.18)$$

Fisher'in ölçüsü iki koşulu sağlamaya çalışır:

- Sınıf merkezleri arası uzaklık en çoklanmalıdır.
- Her sınıfın kendi içindeki dağılımı en az düzeye getirilmelidir.

- Öznitelik Vektör Histogramı

MFCC sonucu elde edilen özniteliklerin hepsi, o sınıfı temsil eden bilgiyi içermiyor olabilir. Bundan dolayı sınıflandırma doğruluk oranı düşebilmektedir. Öznitelik vektör histogramı, bu öznitelikler arasında sınıfı temsil edenleri bulmak

için sınıflandırıcı doğruluk oranları karşılaştırılması yapılarak, en yüksek doğruluk oranını veren öznitelik kombinasyonu seçilmektedir.

2.7. Sınıflandırma

Tyagi, yaptığı çalışmada Bayes sınıflandırıcı ile SVM sınıflandırıcıyı kullanmıştır. İkisinin performanslarını karşılaştırdığında Bayes sınıflandırıcı ile ele aldığı MFCC uygulamasında %98 doğruluk elde ederken, aynı MFCC uygulaması kullanarak SVM sınıflandırıcı ile %100 başarı elde etmiştir [1].

Bhave, çalışmasında LPC ve MFCC özniteliklerini k-NN sınıflandırıcıya giriş olarak vererek, iki öznitelik çıkarım yöntemini karşılaştırmıştır. MFCC temelli öznitelik çıkarımı ile elde edilen doğruluğu %68-96 arasında, LPC temelli öznitelik çıkarım yöntemi ile elde edilen doğruluğu %50-92 arasında bulmuştur [14].

Joshi, çalışmasında MFCC özniteliklerini kullanarak GMM sınıflandırıcı ile %89-96 arası doğruluk elde etmiştir [16].

Borkar, çalışmasında MFCC özniteliklerini kullanarak SVM çekirdeklerini karşılaştırmıştır. SVM sınıflandırıcı çekirdeklerini değiştirdiğinde en iyi başarı oranını quadratik ve polynomial çekirdeklerinde sırasıyla %96 ve %98 elde etmiştir [2].

2.7.1. En Yakın Komşu

K-NN; veri madenciliği (data mining), örüntü tanıma (pattern recognition), görüntü işleme (image processing) ve ses işleme (voice processing) gibi pek çok alanda kullanılan denetimli öğrenme (supervised learning) tekniklerinden biridir.

Sorgulanan örneğin sınıfını, örneğe en yakın K adet eğitim örneğinin sınıflarına göre belirler. Mesafe ölçüsü için genellikle Öklid mesafesi kullanılır. K adet eğitim örneği içinde en çok elemana sahip olan sınıf, sorgulanan örneğin de sınıfı kabul edilir [45], [46].

- Bu yöntem örnek kümedeki gözlemlerin her birinin, sonradan belirlenen bir gözlem değerine olan uzaklıklarının hesaplanması ve en küçük uzaklığa sahip k sayıda gözlemin seçilmesi esasına dayanmaktadır.

- Uzaklıkların hesaplanmasında, i ve j noktaları için Öklid uzaklık formülü kullanılabilir.

$$d(i, j) = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (2.19)$$

- K parametresi belirlenir. (Bu parametre verilen bir noktaya en yakın komşuların sayısıdır.)
- Söz konusu nokta ile diğer tüm noktalar arasındaki uzaklıklar tek tek hesaplanır.
- Yukarıda hesaplanan uzaklıklara göre satırlar sıralanır ve bunlar arasından en küçük olan k tanesi seçilir.
- Seçilen satırların hangi kategoriye ait oldukları belirlenir ve en çok tekrar eden kategori değeri seçilir.
- Seçilen kategori, tahmin edilmesi beklenen gözlem değerinin kategorisi olarak kabul edilir.

- Avantaj

- Uygulanması basit
- Gürültülü verilere karşı etkili
- Eğitim dokümanlarının sayısı fazla ise daha etkindir

- Dezavantaj

- Algoritma başlangıçta K parametresine ihtiyaç duyar
- En iyi sonucun alınabilmesi için hangi uzaklık ölçümünün uygulanacağı ve hangi özelliklerin alınacağı bilgisi açık değildir
- Hesaplama maliyeti yüksektir

2.7.2. Bayes Sınıflandırma

Bayes sınıflandırma tekniği, elde var olan, hali hazırda sınıflanmış verileri kullanarak yeni bir verinin mevcut sınıflardan herhangi birine girme olasılığını hesaplayan bir yöntemdir. Bayes teoremi Eşitlik 2.20'deki gibi ifade edilebilir [45], [46].

$$P(C_1 | x_i) = \frac{P(x_i | C_1) P(C_1)}{P(x_i | C_1) P(C_1) + P(x_i | C_2) P(C_2)} \quad (2.20)$$

Burada C_1 ve C_2 olarak gösterilen iki ayrı hipotezin, başka bir deyişle iki ayrı sınıfın olduğu kabul edilmiştir. $P(C_1 | x_i)$ x_i 'nin C_1 sınıfında olma olasılığını ifade etmektedir. $P(x_i)$, x_i değerinin veritabanındaki bulunma sıklığı sayısıdır. $P(C_1)$ ve $P(C_2)$ ise C_1 ve C_2 sınıflarının veritabanında bulunma sıklığıdır. Eğer m adet sınıf olduğu düşünülürse bu durumda kural Eşitlik 2.21'deki gibidir.

$$P(x_i) = \sum_{j=1}^m P(x_i | C_j) P(C_j) \quad (2.21)$$

Bu durumda x_i 'nin C_1 sınıfında olma olasılığı Eşitlik 2.22 bağıntısı ile hesaplanır.

$$P(C_1 | x_i) = \frac{P(x_i | C_1) P(C_1)}{P(x_i)} \quad (2.22)$$

Bayes algoritması, öncelikle kendisine verilen öğrenme kümesinde $P(C_j)$ değerini, her sınıfın verilen öğrenme kümesi içinde bulunma sıklığını hesaplar. Daha sonra, x_i 'ler sayılarak $P(x_i)$ değeri bulunur. Benzer şekilde her bir sınıfta, her bir x_i değerinin bulunma sıklığı, $P(x_i | C_j)$, C_j 'ler içinde x_i 'lerin sayılmasıyla elde edilir.

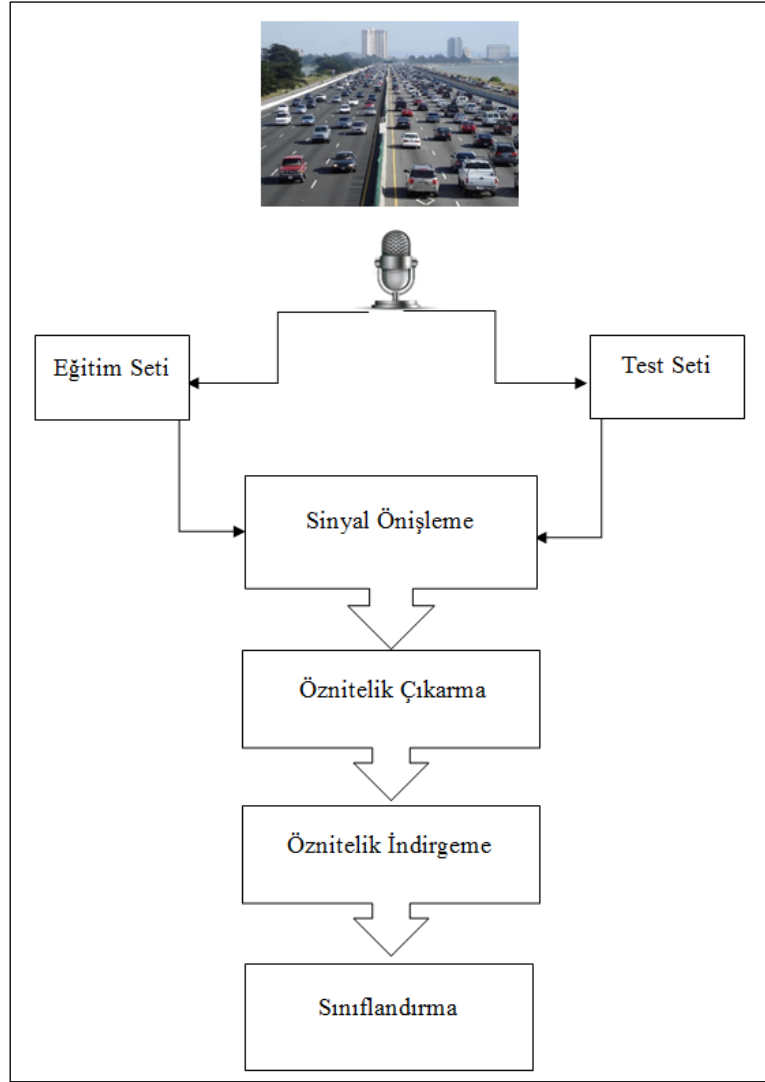
2.7.3. Destek Vektör Makinası

Veri madenciliğinde sınıflandırma problemlerinde kullanılan bir diğer yöntem Destek Vektör Makinası (SVM) adını taşımaktadır. Bu yöntem, sınıflandırmayı bir doğrusal ya da doğrusal olmayan bir fonksiyon yardımıyla yerine getirir. Destek vektör makinası yöntemi, veriyi birbirinden ayırmak için en uygun fonksiyonun tahmin edilmesi esasına dayanır [45], [46].

SVM, denetimli öğrenmede çok geniş kullanıma sahiptir ve genellikle sınıflandırma ve regresyon için kullanılır. SVM, linear ve linear olmayan verileri sınıflandırabilir [31].

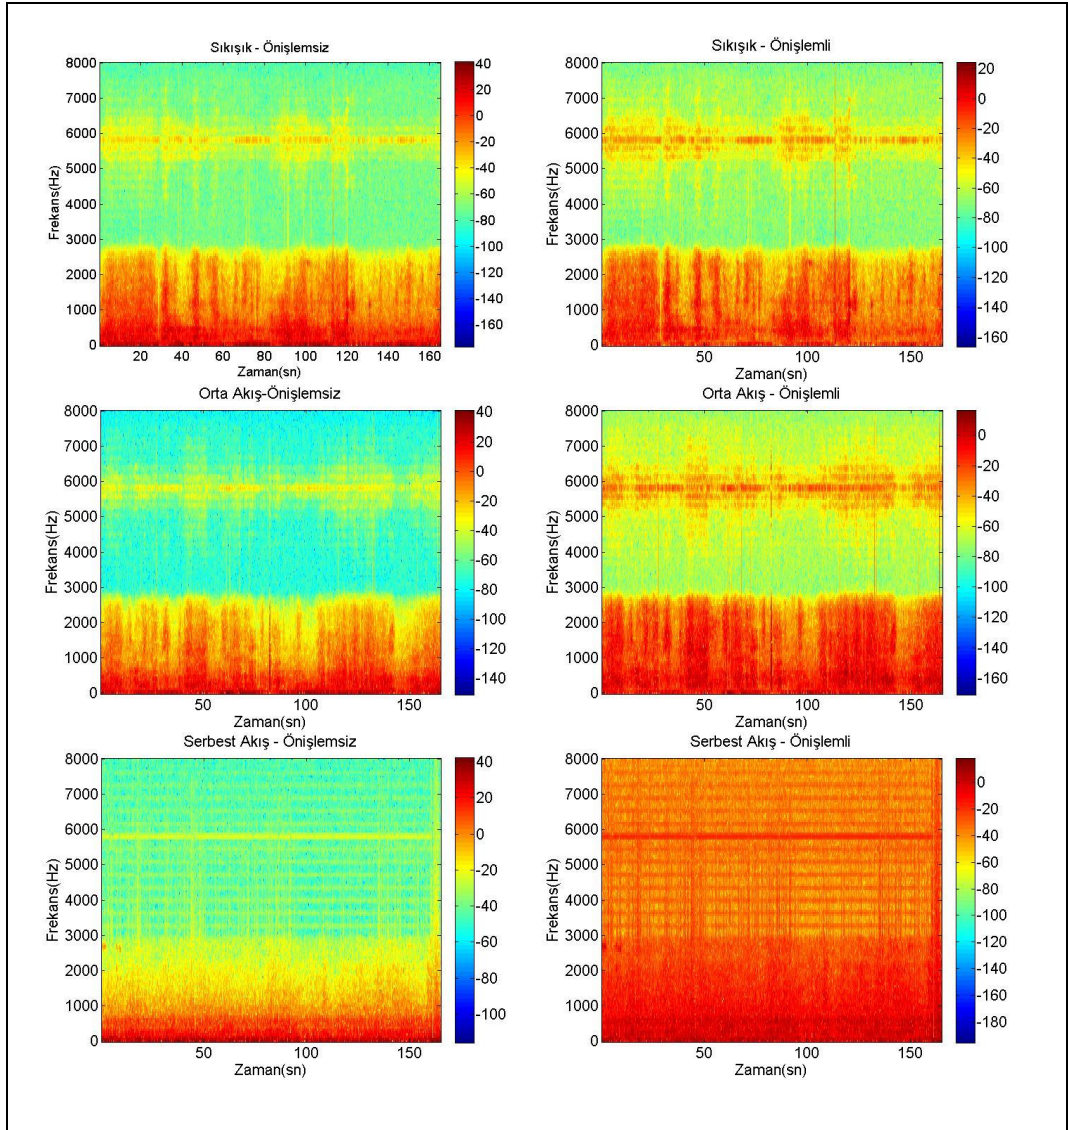
3. TRAFİK YOĞUNLUĞU TESPİT YAKLAŞIMI

Klasik trafik yoğunluğu tespiti Şekil 3.1’de görüldüğü gibi yol kenarındaki ses sinyalinin akustik sensörler ile algılanması, ön işleme ile gürültüden arındırılması, öznelilik çıkarımının gerçekleştirilmesi ve sonrasında sınıflandırıcı ile trafik yoğunluğu tespitinin sonuçlanması aşamalarından oluşmaktadır. Akustik sinyalin algılanması ile yol kenarındaki ham ses verisi toplanmıştır. Ön işleme aşamasında gürültüden arındırılmıştır ve sinyalin özneliliklerini çıkaracak hale getirilmiştir. Öznelilik çıkarımı ön işleme ile oluşan sinyali niteleyen özellikler kümesini ifade etmektedir. Sınıflandırma aşamasında ilk olarak veri kümesi oluşturulur ve sonradan test edilmek istenen ses sinyali sisteme verilerek sınıflandırıcı sonucu elde edilir.



Şekil 3.1: Trafik yoğunluğu tespit tasarım aşamaları.

Bu çalışmanın ilk amacı trafik yoğunluğunun akustik sinyallerle tespit edilebileceğinin gösterilmesidir. Bu amaç doğrultusunda Şekil 3.1'deki aşamalar tüm çalışma boyunca hava koşulları dikkate alınmadan gerçekleştirilmiştir. Birçok çalışmada yol kenarındaki akustik sinyal ile trafik yoğunluğunun tespiti yapılmıştır, fakat bu çalışmada veri seti farklı hava koşulları ve farklı yollarda toplanmıştır, bundan dolayı ilk olarak veri setindeki bazı verilerin spektrumları incelenmiştir. Trafik yoğunluğu durumlarının ayrı ayrı akustik spektrumları Şekil 3.2'de gösterilmiştir.



Şekil 3.2: Trafik yoğunluğu akustik spektrumları.

Şekil 3.2'de gösterildiği gibi trafik yoğunluğu durumları arasında akustik spektrum farklılıkları görülmüştür. Akustik spektrumdaki farklılık trafik yoğunluk

durumlarının akustik sinyal ile ayırt edilebileceğini göstermiştir. Spektrumlarda trafik yoğunluğunun sıkışık olduğu durum ile orta-akış olduğu durum arasında çok az fark gözlemlenmiştir. Ancak trafiğin serbest-akış durumu ile diğer ikisi arasında büyük farklılık gözlemlenmiştir. Trafik yoğunluk durumlarının akustik spektrumlarının farklılık göstermesi bir sonraki çalışma için motive etmiştir.

Çalışma boyunca tüm aşamalarda parametreler değiştirilerek, parametrelerin sistem üzerindeki etkileri analiz edilmiştir. En iyi performansı gösteren parametrik yapı, her aşamanın sonunda bir sonraki aşamaya giriş olarak verilmiştir.

Bu doğrultuda ilk olarak akustik sinyalin ön işlem aşamasından geçip geçmeyeceği ve geçmesi durumunda a parametresinin alacağı değerin belirlenmesi gerçekleştirilmiştir.

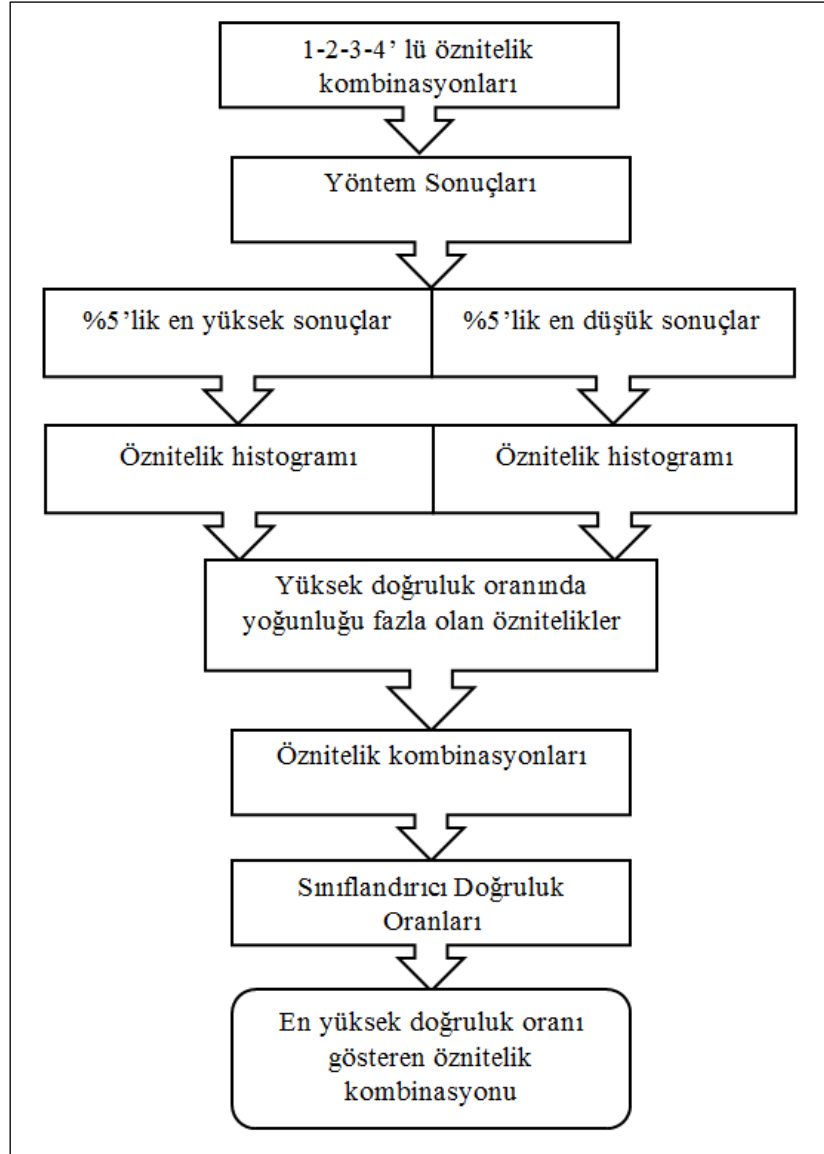
Öznitelik çıkarım aşamasında ilk olarak MFCC algoritmasının parametreleri değiştirilerek analizler yapılmış ve en yüksek performansı veren MFCC parametreleri seçilmiştir.

Ses sinyalinden elde edilen özniteliklerden bazıları gereksiz olduğu gibi öznitelik miktarı çok fazla olabilmektedir. Gereksiz veri ve verinin çok fazla olması sınıflandırma performansını etkilemektedir. Öznitelik sayısının azaltımı ve boyutunun azaltımı önem arz etmektedir. Bu çalışmada genel olarak Temel Bileşenler Analizi, Doğrusal Ayrışım Analizi, Entropi Ölçütü ve Fisher Ölçütü kullanılarak öznitelik indirgeme yapılmıştır. Ayrıca öznitelik vektör histogramı adını verdiğimiz öznitelik seçim tekniği de kullanılmış ve diğer yöntemlere göre performans karşılaştırılması yapılmıştır.

Öznitelik vektör histogramı; öznitelikler arasında sınıfı temsil edenleri bulmak için sınıflandırıcı doğruluk oranları karşılaştırılması yapılarak, en yüksek doğruluk oranını veren öznitelikler kombinasyonu seçilir. Tüm özniteliklerin kombinasyonunun denenmesi maliyetli olduğundan, öznitelik vektör histogramı adı verdiğimiz yöntem kullanılmıştır.

Öznitelik vektör histogram yöntemi, öznitelikleri 1-2-3-4'lü kombinasyonlar halinde sınıflandırıcıya giriş olarak verir. Sınıflandırıcı doğruluk oranlarının %5'lik en yüksek kısımdaki öznitelik histogramı ile %5'lik en düşük kısımdaki öznitelik histogramı karşılaştırılır. Yüksek doğruluk oranında yoğunluğu fazla olan öznitelikler seçilir ve seçilen bu özniteliklerden yeni kombinasyonlar oluşturularak sınıflandırıcıya giriş olarak verilir. Elde edilen doğruluk oranlarından en yüksek

doğruluğa sahip öznitelik kombinasyonu seçilir. Şekil 3.3'te öznitelik vektör histogram yönteminin akış diyagramı gösterilmiştir.

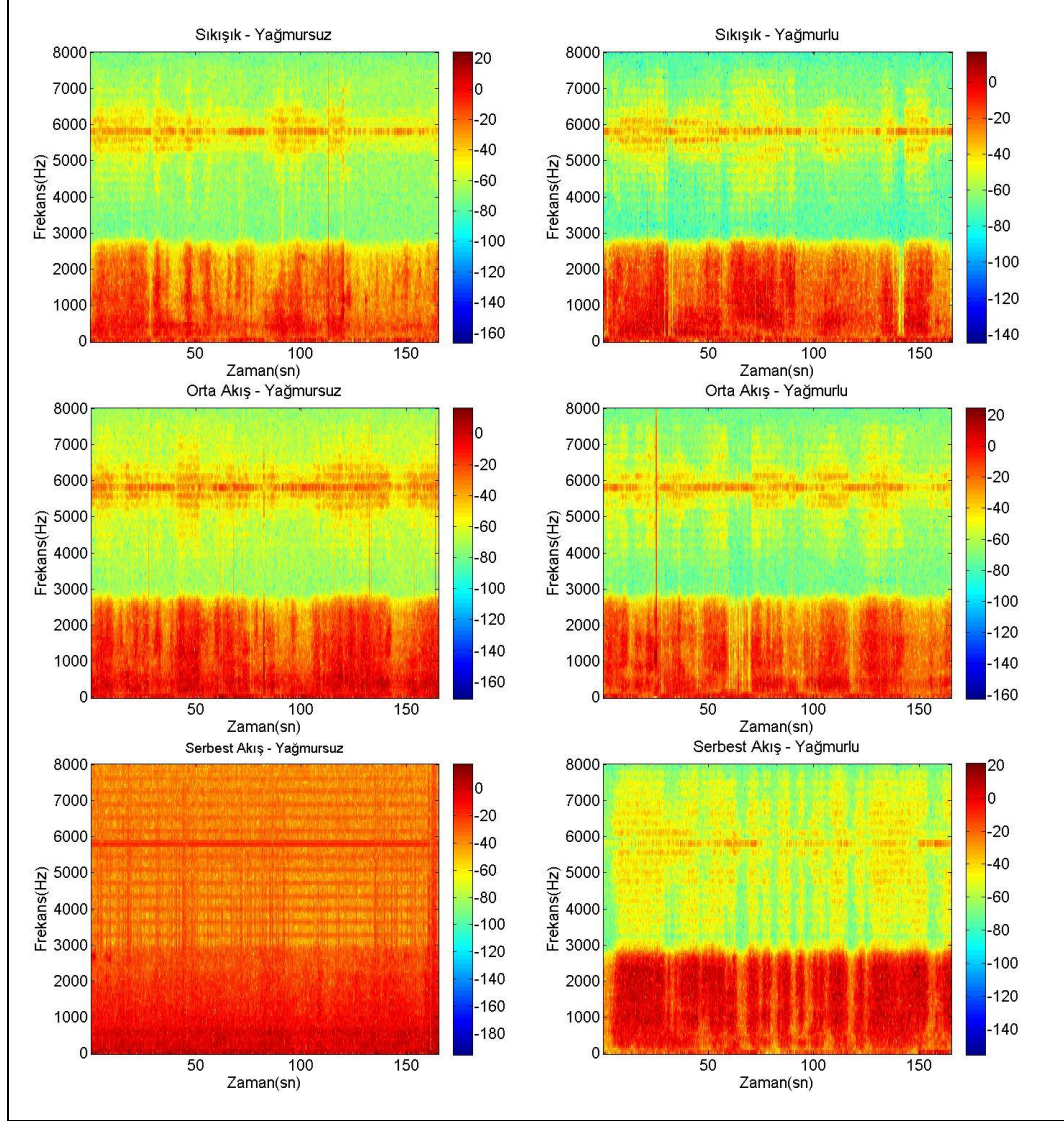


Şekil 3.3: Öznitelik vektör histogramı.

Öznitelik seçiminden sonra sınıflandırıcı performansları incelenmiş ve hava koşulları dikkate alınmadığı zaman trafik yoğunluğu tespit performansı elde edilmiştir. Bu performans değeri ileride yapılacak hava koşulları dikkate alındığında elde edilecek performans değerleri ile karşılaştırılmıştır. Böylece hava koşulları dikkate alındığında ileri sürülen yöntemin performans etkisi gözlemlenmiştir.

Bu çalışmanın ana amacı “hava koşulları dikkate alınarak trafik yoğunluğu tespitinin daha yüksek doğrulukla” elde edilebileceğinin gösterilmesidir. Bu durumu

gerçekleyebilmek için yağmurlu-yağmursuz hava koşulları dikkate alınmıştır. İlk olarak yağmurlu-yağmursuz hava koşullarında akustik spektrum analizleri incelenmiştir. Yağmursu ve Yağmurlu hava koşullarında trafik yoğunluğu durumlarının ayrı ayrı akustik spektrumları Şekil 3.4'te gösterilmiştir.



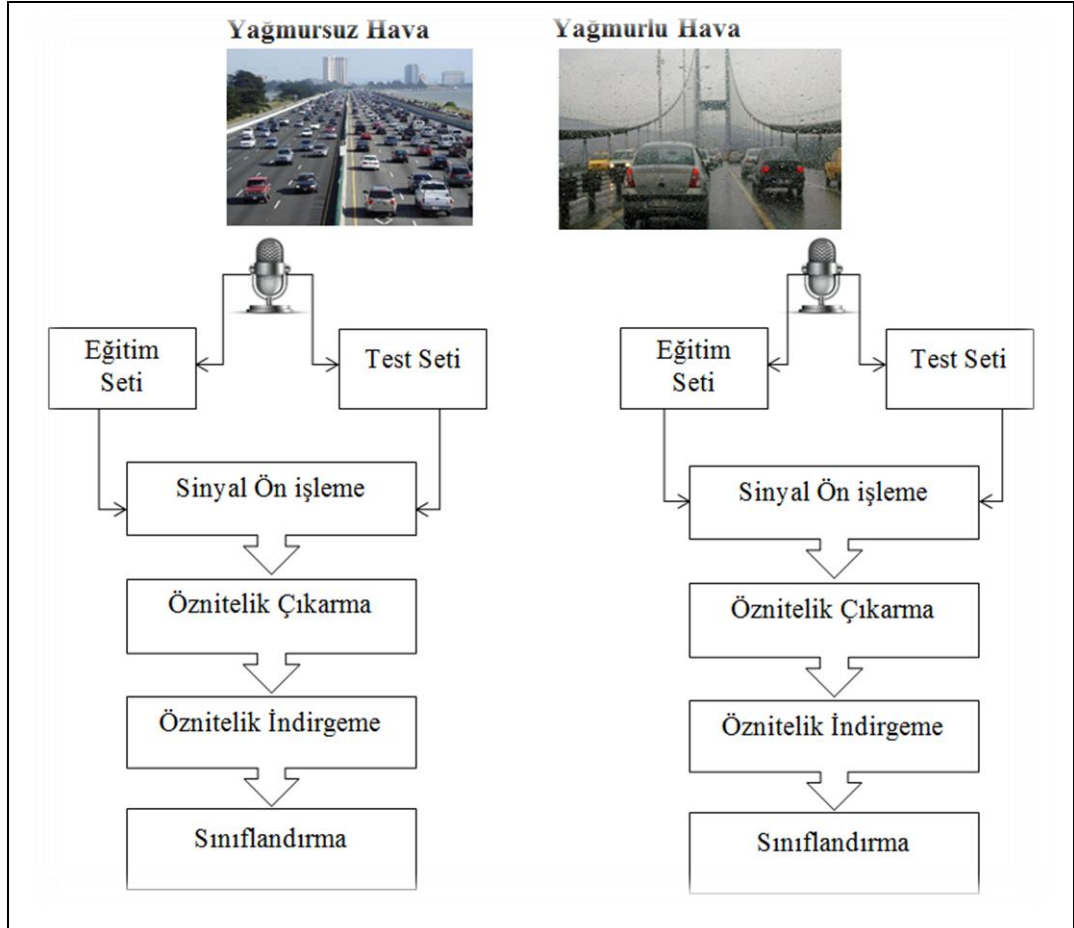
Şekil 3.4: Yağmursuz-Yağmurlu havada trafik yoğunluğu akustik spektrumları.

Şekil 3.4'te gösterildiği gibi yağmursuz hava koşullarındaki akustik spektrum ile yağmurlu hava koşullarındaki akustik spektrum arasında trafik yoğunluğu durumlarının her biri için farklılığın olduğu gözlemlenmiştir.

Aynı zamanda yağmurlu hava koşullarında trafik yoğunluğu durumları arasında akustik spektrum farklılıkları görülmüştür. Akustik spektrumdaki farklılık

yağmurlu hava koşullarında trafik yoğunluk durumunun akustik sinyal ile ayırt edilebileceğini göstermiştir.

Hava koşulları dikkate alındığında Şekil 3.5'te gösterildiği gibi iki farklı veri seti ve iki farklı akış diyagramı oluşturulmuştur.



Şekil 3.5: Hava koşulları ile trafik yoğunluğu tespit yaklaşım aşamaları.

Bu çalışmada, hava koşulları dikkate alınmadan tüm veri seti ile Şekil 3.1'deki klasik trafik yoğunluğu tespiti adımları ve hava koşulları dikkate alınarak Şekil 3.5'teki trafik yoğunluğu tespiti adımları gerçekleştirilmiş olup Bölüm 4'te yapılan deneysel sonuçlar anlatılmıştır.

4. DENEYSEL SONUÇLAR

Bu çalışmada, trafik yoğunluğu tespitinin akustik sinyal verisi ile yapılabileceği ve trafik yoğunluğu tespitinde hava koşullarının göz önüne alınması ile performansın artabileceği gösterilmiştir.

4.1. Veri Setinin Oluşturulması

Veri seti hazırlanması, verilerin toplanması, toplanan verilerin örnek verileri oluşturacak şekilde bölümlenmesi ve eğitim/test verilerin belirlenmesi olmak üzere üç aşamada gerçekleşmiştir.

Verilerin toplanması aşamasında STM32F4 Discovery kiti üzerindeki omnidirectional mikrofondan alınan veri hiçbir işleme girmeden bilgisayara aktarılmıştır. Veriler şehir içi, şehir dışı (E-5 karayolu) yollarında, farklı günlerde ve farklı hava koşullarında toplanmıştır. Toplam veri ‘sıkışık (Jammed)’, ‘orta-akış (mid-flow)’ ve ‘serbest-akış (free-flow)’ durumlarını kapsadığı gibi, yağmurlu, yağmursuz, rüzgârlı ve rüzgârsız hava koşullarını da kapsamaktadır. Veri toplama, farklı günlerde genelde 16.00-20.00 saatleri arasında olmakla birlikte, sabah saatlerini de kapsamaktadır. Veri toplama lokasyonu olarak Gebze-Pendik E-5 karayolu arasındaki farklı yerlerden oluşmaktadır. Ses verisi toplama ile eş zamanlı İBB Trafik Yoğunluk Haritasından o andaki trafik yoğunluğu durumu ve ortalama hızlar kayıt edilmiştir. Aynı zamanda ses toplama ile eş zamanlı olarak yolun kamera görüntüsü de kayıt altına alınmıştır. Ses verisi 15’er dakikalık aralıklarla kayıt altına alınmıştır ve toplamda 1200 dakika toplanmıştır.

Veriler, veri örneklerini oluşturacak şekilde 30 saniye ve 1 dakikalık parçalara bölümlendirilmiştir. Her bir kısım bir örneği oluşturmak üzere belli bir isimlendirme kuralı ile kayıt altına alınmıştır. İsimlendirme kuralında, dosya isimlerine bakıldığında sesin hangi tarihte, saatte, hangi hava koşullarında toplandığı ve trafik yoğunluk durumlarından hangisine ait olduğu anlaşılmaktadır. Bu sayede yapılacak tüm deneylerde kolaylık olması açısından örnekler bir klasör içinde toplanmıştır.

Veri Örneklerin İsimlendirme Formatı;

TR/TS-Tarih-Saat-Hava Koşulları – Trafik Yoğunluk Durumu_Kacinci Dakika
Örnek dosya ismi; TR03-02-2015-15-10-YYRYSY-FFAC_01

Örnekte görüldüğü gibi bu veri 03.02.2015 tarihinde 15.10'da toplanmış. Hava koşulları 'Yağmur Yok (YY)', 'Rüzgâr Yok (RY)' ve 'Sıcaklık Yok (SY)' olarak görünmektedir. Trafik yoğunluğu hakkında iki veri içermektedir. 'FF' olarak nitelendirilen genelde makalelerde geçen 'Serbets-Akış (FreeFlow)' u ifade etmektedir. 'AC' ise İBB Trafik Yoğunluk Haritasında 'Açık'ı ifade etmektedir. En sonda bulunan '01' verinin toplanmaya başlandığı 15.10 saatinden itibaren birinci dakikayı ifade etmektedir. Aynı zamanda baştaki TR eğitim (train) , TS test verisi olduğunu ifade etmektedir. Bu sayede tüm veri aynı klasör içinde depolanarak veri ambarı oluşturulmuştur.

Tüm veri içinde trafik yoğunluğu durumuna göre tüm gruplar mevcut olduğu gibi farklı hava koşullarına göre de örnekler bulunmaktadır. Bundan dolayı test verisi her gruba ait toplam veri sayısının %50'si olacak şekilde seçilmiştir. Bir dakikalık veriler düşünüldüğünde toplam 1200 dakikalık veriden, 600 dakikası eğitim verisi, 600 dakikası test verisi olacak şekilde ve test verisinde trafik yoğunluk durumunun her birisi için farklı hava koşulları olacak şekilde homojen bir dağılım ile eğitim ve test verisi oluşturulmuştur.

4.2. Literatürdeki Çalışmanın Gerçekleşmesi

Tyagi çalışmasında verileri şehir içinde ve 5-8 şeritli bir yolda toplamıştır. Özellikle trafik yoğunluğunun sıkışık olduğu anda araçlar 8 şerit olmuş, birbirlerinin önüne geçmeye çalışan ve araç kornalarının çok fazla kullanıldığı bir ortamda toplanmıştır. Trafik yoğunluğunun sıkışık olduğu andaki korna sesleri ayırt edici özellik olmuştur. Yaptığı çalışmada 30 saniyelik örneklerin 500 ms pencere süresi ve 100 ms kaydırma süresi olacak şekilde MFCC işleminden geçirerek 12 öznitelik hesaplamıştır. Bayes ve SVM sınıflandırıcı kullanarak her sınıf için doğruluk oranını yaklaşık %100 bulmuştur.

Bu çalışmada da aynı şekilde şehir içinden toplanan veriler kullanılarak aynı MFCC uygulaması ve sınıflandırıcı ile yaklaşık %100 başarı elde edilmiştir. Ancak E-5 otoyolunda topladığımız veri setini kullandığımızda aynı MFCC uygulaması ve sınıflandırıcı ile yaklaşık %64.8-68.1 arası başarı elde edilmiştir. Bu başarı oranı Tyagi'nin başarı oranından daha düşüktür. Tyagi'nin veri setinden farklı olarak E-5 otoyolunda araçlar nadiren korna çalıyor olması veri setleri arasındaki sonuca etki edecek en belirgin özelliktir.

E-5 otoyolundan toplanan veri seti ile Tyagi'nin çalışmasında bahsedilen MFCC uygulaması ve sınıflandırıcı yöntemleri kullanılarak başarı oranı hesaplanmıştır. Yapılan çalışma parametreleri aşağıda belirtildiği gibi hesaplamaya dahil edilmiştir. Tablo 4.1'de gösterildiği gibi performans elde edilmiştir.

- Eğitim Seti : 30 saniyelik 1200 örnek
- Test Seti : 30 saniyelik 1200 örnek
- MFCC Öznitelik Sayısı : 12
- MFCC Pencere Süresi : 500 ms
- MFCC Pencere Kaydırma Süresi : 100 ms

Tablo 4.1: E-5 Otoyolu veri setinin literatür çalışmasına göre performansları.

Trafik Yoğunlukları	Bayes Performansı	SVM Performansı
Sıkışık	%70.3	%75.8
Orta-Akış	%71.2	%55.7
Serbest-Akış	%48.9	%71.1
Tüm Veri Seti	%64.8	%68.1

Tablo 4.1'de görüldüğü gibi başarı oranı iki sınıflandırıcı için farklı ve Tyagi'nin çalışmasından düşüktür. Bu analizde Tyagi'nin çalışmasından farklı olan veri setidir. Tyagi veri setini şehir içi trafik ortamında topladığından dolayı veri setinde korna sesi oranı çok yüksek olabilir. Bu çalışmada, veri seti E-5 otoyolundan toplandığı için, daha az korna olmasının yanı sıra zaman zaman araçların emniyet şeriti kullanması gibi nedenler başarı oranında etkili olmuş olabilir.

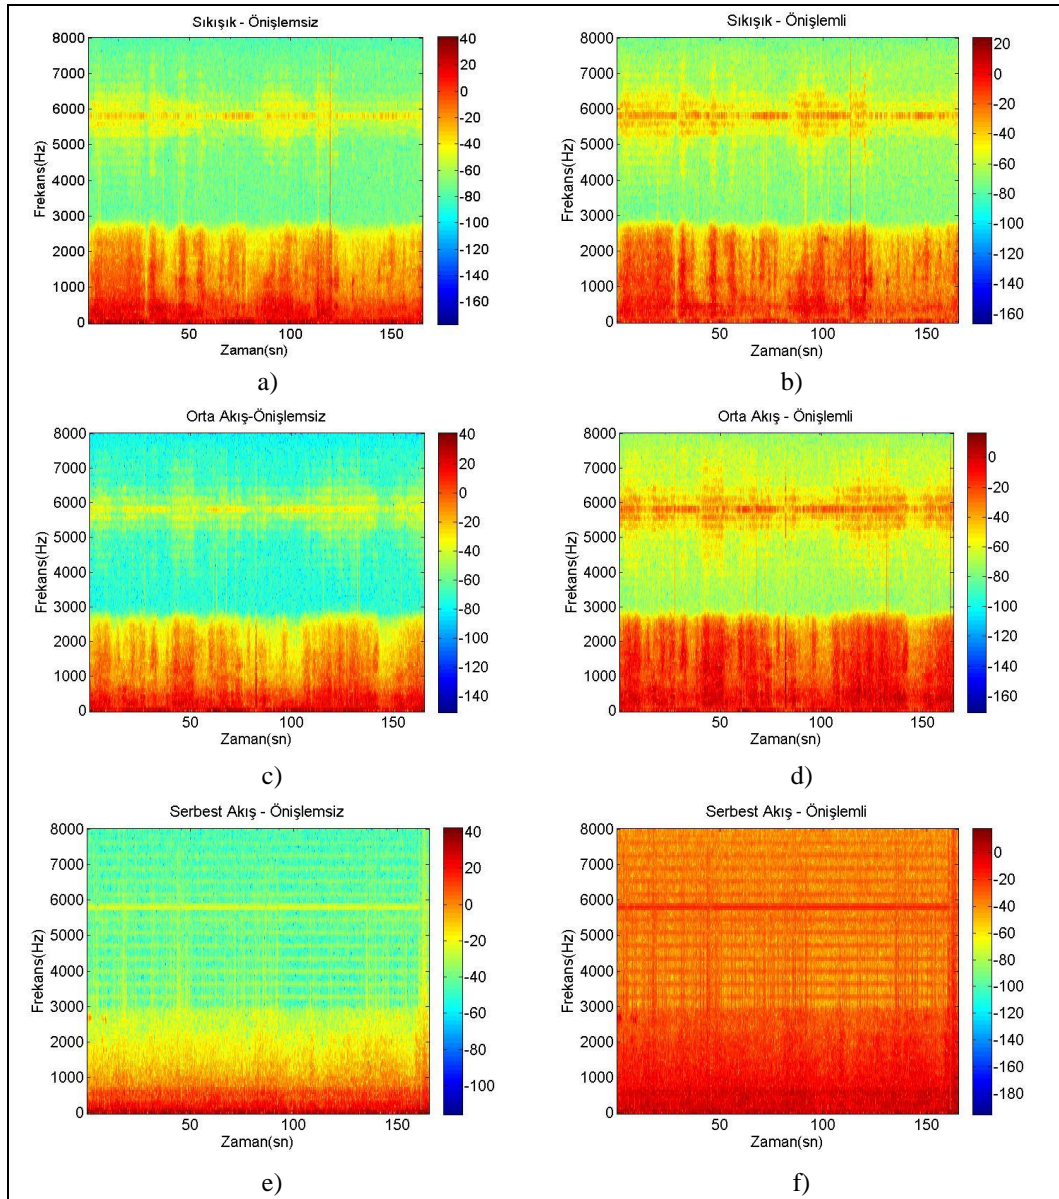
4.3. Verileri Önleme

Sensör ile toplanan akustik sinyalde gürültü sinyalleri de oluşacaktır. Bunlar rüzgârın sensöre etkisi ile oluşan gürültü, çevreden gelen gürültü veya sensör ile sistem arasında oluşabilecek gürültülerdir. Bu gürültüler sinyallerinin durması sinyal üzerinde yapılacak işlemlerin başarısını azaltmaktadır [30]. Bundan dolayı ses sinyalinin gürültülerden arındırılması ve yüksek frekansların daha baskın hale getirilmesi için akustik sinyal ilk olarak ön işleme fazından geçirilir. Bu çalışmada kullanılan veri setinde gürültünün azaltılması ve yüksek frekansların daha baskın

hale getirilmesinin etkisi ilerleyen konu spektrum ve sınıflandırma analizlerinde incelenmiştir.

4.3.1. Spektrum Analizi

Spektrum Analizi, sinyalin zamana göre frekans içeriğinin nasıl değiştiğinin gösterimidir. Zaman eksenini x , frekans eksenini y ve sinyalin herhangi bir zamandaki enerjisi renk seviyeleri ile gösterilmektedir. Düşük enerji yoğunluğu olduğu yerler açık renkli, yüksek enerji yoğunluğu olduğu yerler koyu renklidir.



Şekil 4.1: Akustik sinyalin önışlemsiz-önışlemlı spektrum analizleri. a) Sıkışık-önışlemsiz, b) Sıkışık-önışlemlı, c) Orta akış-önışlemsiz, d) Orta akış-önışlemlı, e) Serbest akış-önışlemsiz, f) Serbest akış-önışlemlı.

Bu çalışmada kullanılan veri setinde gürültü sinyalinin etkisini ve yüksek frekansların daha baskın hale getirilmesini gözlemek için; Trafik yoğunluğu durumlarının her bir örneğinin spektrum analizi ile her bir örneğin ön işlemlerli spektrum analizi Şekil 4.1’de gösterildiği gibi karşılaştırılmıştır.

Şekil 4.1.a) ve Şekil 4.1.b)’de trafik yoğunluk durumunun yoğun olduğu grubun spektrumu, Şekil 4.1.c) ve Şekil 4.1.d)’de trafik yoğunluk durumunun orta-akış olduğu grubun spektrumu, Şekil 4.1.e) ve Şekil 4.1.f)’te trafik yoğunluk durumunun serbest akış olduğu grubun spektrumu gösterilmiştir.

Şekil 4.1.a), Şekil 4.1.c) ve Şekil 4.1.e) grafiklerinde ses işareti hiçbir işleme girmeden spektrumu gösterilmiştir. Şekil 4.1.b), Şekil 4.1.d) ve Şekil 4.1.f) grafiklerinde ses işareti ön işleme girerek spektrumu gösterilmiştir. Akustik sinyalin ön işlemsiz spektrumuna bakıldığında çok düşük frekansların enerji yoğunluklarının çok yüksek olduğu gözlemlenmiştir. Yüksek frekansların enerji yoğunluğu düşük frekansa göre çok iyi belirmemektedir. Bundan dolayı yüksek frekanslı bölgeleri güçlendiren filtreleme uygulandığında Şekil 4.1’de ikinci sütundaki grafiklerdeki netice gözlemlenmiştir. Görüldüğü gibi yüksek frekanslardaki enerji yoğunluğu ortaya çıkmıştır.

4.3.2. Sınıflandırma Analizi

Bu çalışmada kullanılan veri setinde gürültü sinyalinin etkisini gözlemek için sınıflandırıcı başarı oranları karşılaştırılması analizi yapılmıştır.

Tüm veri setinin ön işlemlerli ve ön işlemsiz MFCC öznitelikleri çıkartılmıştır. Ön işlemlerli $a = 0.90$, $a = 0.95$ ve $a = 0.97$ olmak üzere üç farklı ön işlemlerli MFCC öznitelikleri çıkartılmıştır. MFCC öznitelikleri K-NN sınıflandırıcıya giriş olarak verilmiştir. Elde edilen sınıflandırıcı doğruluk oranları Tablo 4.2’de gösterildiği gibi elde edilmiştir.

Tablo 4.2: Ön işlemsiz - Ön işlemlerli akustik sinyalin sınıflandırıcı performansları.

	Ön işlemsiz	Ön işlemlerli ($a = 0.90$)	Ön işlemlerli ($a = 0.95$)	Ön işlemlerli ($a = 0.97$)
K-NN Sınıflandırıcı Performansı	%78	%79	%79	%79

Tablo 4.2’de gösterildiği gibi a parametresi 0.90, 0.95 ve 0.97 olduğu zaman ki performansları %79 ve tüm a değerlerinde eşit olduğu gözlemlenmiştir. Ön işlemsiz durumda %78 performans görülmüştür. Akustik sinyalin ön işlemlenmiş durumunda çok küçük de olsa performans artışı olmuştur. Bu analizden sonra çalışmanın devamında yapılacak tüm analizler ön işlem hesaplanarak yapılmıştır.

4.4. MFCC Özniteliklerinin Oluşturulması

Bu çalışmada, en iyi sınıflandırma doğruluk oranını veren öznitelik seçimi yapılacağından dolayı MFCC yöntemi ile özniteliklerin elde edilmesinde çok farklı parametrik yapılarla farklı MFCC uygulamaları kullanılmıştır. MFCC uygulamasında Mel-filtre sayısı, MFCC Kepstrum Katsayı sayısı, pencere süresi ve pencere kaydırma süresi gibi parametreler değiştirilerek farklı MFCC uygulamaları elde edilmiştir. Kullanılan parametrelerin aldığı değerler aşağıda belirtildiği gibidir.

- Mel-filtre sayısı: 6, 16, 24, 34, 44, 64, 74
- Kepstrum katsayı sayısı: 2,4,8,12,16,22,26 ,32,36 ,42,46,52,56,62
- Pencere süresi ve kaydırma süresi: 10-5, 20-10, 50-25, 100-50, 200-100, 400-200, 600-300 ms

Tüm MFCC uygulamaları sonucu elde edilen MFCC Kepstrum Katsayıları(Öznitelikler) kayıt altına alınmıştır.

4.5. Farklı Parametreler ile MFCC Uygulamaları

MFCC uygulamaları sonucu elde edilen MFCC özniteliklerinin ortalaması ve standart sapması ayrı ayrı hesaplanarak Bayes, kNN ve SVM sınıflandırıcıya giriş olarak verilmiştir. MFCC uygulamalarına karşılık gelen her bir doğruluk oranı kayıt altına alınmıştır.

MFCC parametreleri değiştirilerek elde edilen MFCC özniteliklerinin ortalaması ve standart sapması ayrı ayrı Bayes, K-NN ve SVM sınıflandırıcılarına giriş olarak verilmiştir. Tablo 4.3’te gösterildiği gibi sonuçlar elde edilmiştir.

Tablo 4.3: Ortalama ve standart sapmaya göre sınıflandırıcı performansları.

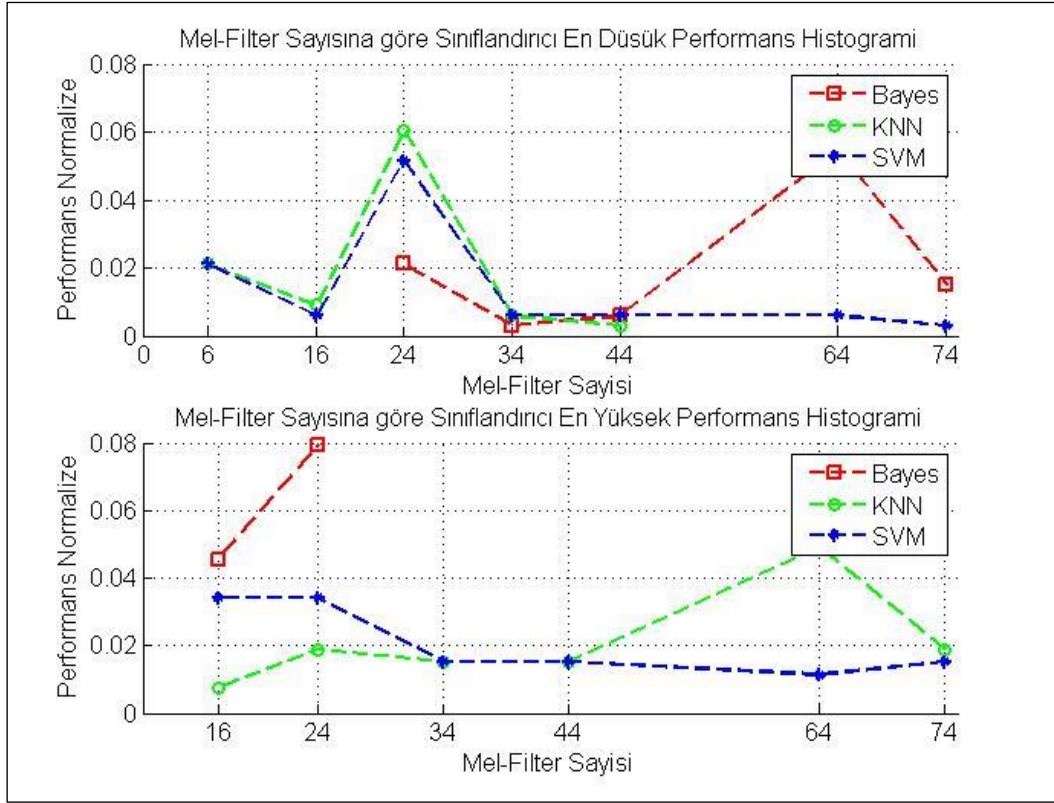
	Ortalama	Standart Sapma
Bayes En Düşük-Yüksek Doğruluk	%53.8 - % 69.3	%46.1 - % 49.3
KNN En Düşük-Yüksek Doğruluk(k=3)	%61.3 - % 79.8	%45.6 - % 61.3
SVM En Yüksek Doğruluk	%66.5 - % 78.1	%51 - % 67

Konuşma ve müzik tanıma çalışmalarında MFCC özniteliklerinin standart sapma ile daha iyi sonuçlar elde edilmiştir [51]. Ancak bu çalışmada MFCC özniteliklerinin ortalaması kullanıldığında %53.8-79.8 arası doğruluk elde edilirken, MFCC özniteliklerinin standart sapması kullanıldığında %45.6-67 arası doğruluk elde edilmiştir. MFCC özniteliklerinin ortalaması alındığında daha iyi başarı oranı elde edilmiştir.

Tablo 4.3'te görüldüğü gibi MFCC özniteliklerinin ortalaması alınarak yapılan sınıflandırmanın başarı oranı, MFCC özniteliklerinin standart sapması alınarak yapılan sınıflandırma başarı oranından daha yüksek olduğundan, çalışmanın devamında MFCC özniteliklerinin standart sapması hiç kullanılmamış, bunun yerine yalnızca MFCC özniteliklerinin ortalamaları kullanılmıştır.

MFCC uygulamaları sonucu oluşan öznitelikler Bayes, KNN ve SVM sınıflandırıcılarına giriş olarak verildiğinde elde edilen sonuçlar doğruluk oranı sırasına göre kayıtlı edilmiştir. En düşük doğruluk veren %30'luk kısım ile en yüksek doğruluk veren %30'luk kısımlarda parametre bazlı normalize histogramları incelenmiştir.

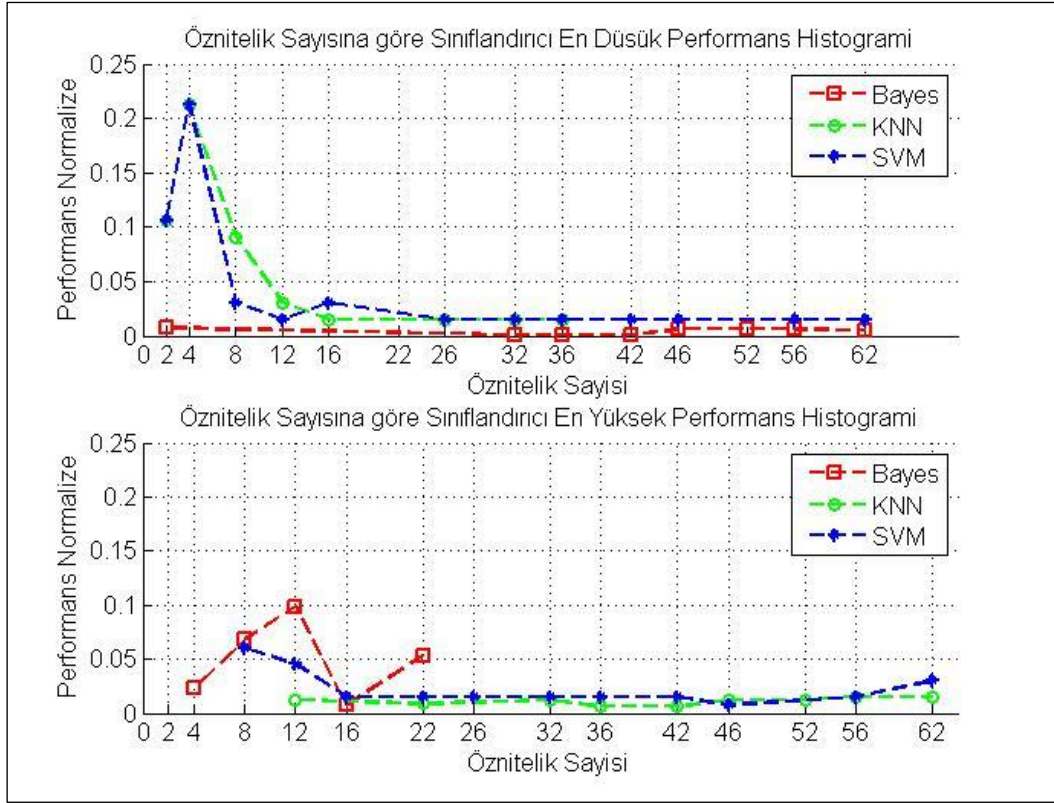
Şekil 4.2'de Mel-filtre sayısına göre sınıflandırıcıların en düşük ve en yüksek performans sonuç histogramı gösterilmiştir.



Şekil 4.2: Mel-filtre sayısına göre sınıflandırıcı performans histogramları.

Şekil 4.2’de üstte bulunan grafik Mel-filtre sayısına göre sınıflandırıcıların en düşük performans histogramı, altta bulunan grafik Mel-filtre sayısına göre sınıflandırıcıların en yüksek performans histogramı gösterilmiştir. Şekil 4.2’de görüldüğü gibi en düşük doğruluk oranlarının yoğunlukta olduğu Mel-filtre sayıları Bayes için 64, K-NN için 24 ve SVM için 24 olduğunda gözlenmiştir. En yüksek doğruluk oranlarının yoğunlukta olduğu Mel-filtre sayısı Bayes için 16-24, K-NN için 64 ve SVM için 16-24 olarak gözlenmiştir.

Şekil 4.3’te Öznitelik sayısına göre sınıflandırıcıların en düşük ve en yüksek performans sonuç histogramı gösterilmiştir.

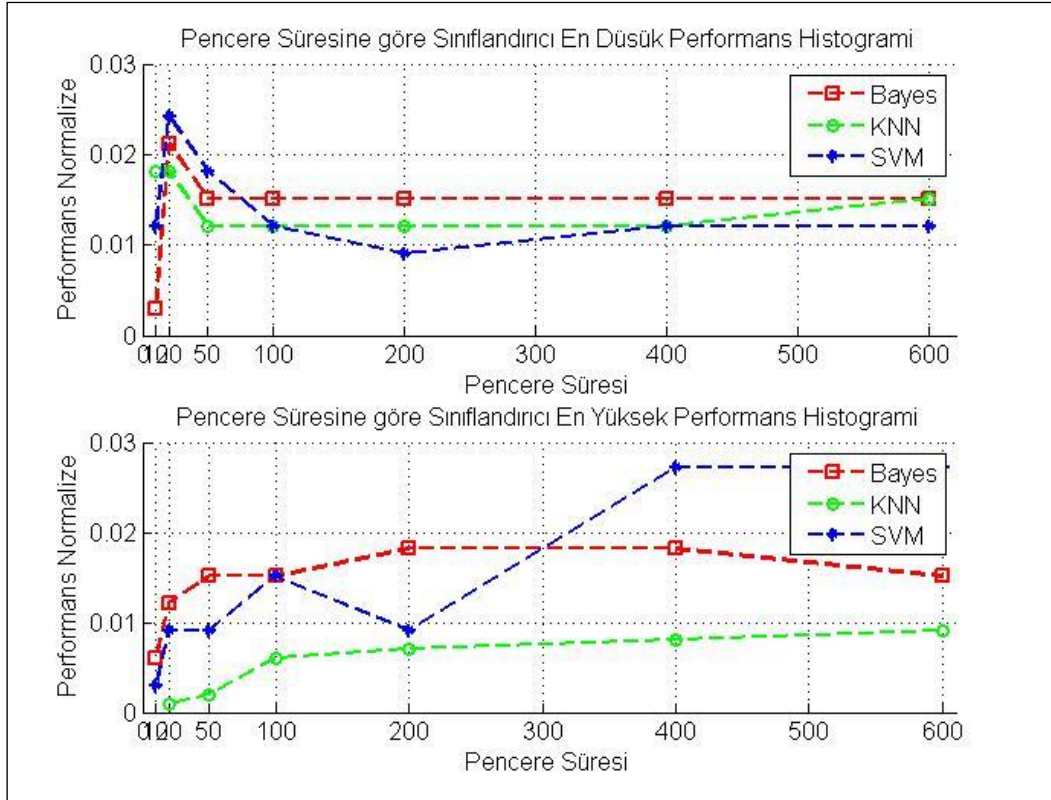


Şekil 4.3: Öznelik Sayısına göre sınıflandırıcı performans histogramları.

Şekil 4.3'te üstte bulunan grafik öznelik sayısına göre sınıflandırıcıların en düşük performans histogramı, altta bulunan grafik öznelik sayısına göre sınıflandırıcıların en yüksek performans histogramı gösterilmiştir. Şekil 4.3'te görüldüğü gibi en düşük doğruluk oranlarının yoğunlukta olduğu öznelik sayıları Bayes için 2-62, K-NN için 4-12 ve SVM için 4 olduğunda gözlenmiştir. En yüksek doğruluk oranlarının yoğunlukta olduğu öznelik sayısı Bayes için 12, K-NN için 62 ve SVM için 8-16, 56-62 olarak gözlenmiştir.

Öznelik sayısına göre sınıflandırıcı performans histogramı analizi sonucu, öznelik sayısı 12 olması performansı artırmıştır.

Şekil 4.4'te Pencere süresine göre sınıflandırıcıların en düşük ve en yüksek performans sonuç histogramı gösterilmiştir.



Şekil 4.4: Pencere Süresine göre sınıflandırıcı performans histogramları.

Şekil 4.4'te üstte bulunan grafik pencere süresine göre sınıflandırıcıların en düşük performans histogramı, altta bulunan grafik pencere süresine göre sınıflandırıcıların en yüksek performans histogramı gösterilmiştir. Pencere süresi 200 ms'nin üstünde olan MFCC uygulamalarında yüksek doğruluk oranlarının yoğunluğu, düşük doğruluk oranlarının yoğunluğundan daha fazladır.

Pencere süresine göre sınıflandırıcı performans histogram analizi sonucu, pencere süresi 200 ms'nin üstü olması performansı artırmıştır.

Bu sonuçlar doğrultusunda yüksek doğruluk oranı parametreleri aşağıdaki gibi ifade edilebilir.

Şekil 4.2 grafiği incelendiğinde Mel-filtre için herhangi bir sonuç çıkarılamamıştır. Bundan dolayı Mel-filtre parametresi haricindeki tüm parametreler sabit olacak şekilde sadece Mel-filtre parametresi değiştirilerek yeni bir analiz yapılmıştır. Bu analiz sonucu Mel-filtre sayısının sınıflandırıcı başarı oranına herhangi bir etkisi olmadığı gözlemlenmiştir.

Şekil 4.3 grafiği incelendiğinde öznitelik sayısı için herhangi bir sonuç çıkarılamamıştır. Bundan dolayı öznitelik haricindeki tüm parametreler sabit olacak

şekilde sadece öznitelik sayısı parametresi değiştirilerek yeni bir analiz yapılmıştır. Bu analiz sonucu öznitelik sayısının sınıflandırıcı başarı oranına herhangi bir etkisi olmadığı gözlemlenmiştir.

Şekil 4.4 grafiği incelendiğinde pencere süresi 200 ms üstü olduğu zaman daha iyi başarı elde edilmiştir.

Tüm sınıflandırıcı sonuçları incelendiğinde, en iyi başarı oranını veren MFCC uygulamalarının parametre değerleri Tablo 4.4’te görüldüğü gibidir.

Tablo 4.4: En yüksek performanstaki MFCC’nin parametrik değerleri.

	Bayes(%69.3)	KNN(%79.8)	SVM(%78.2)
Mel-filtre sayısı	16,16,16,16,16,16	64, 74, 74	16,44,44,74,16,16
Öznitelik sayısı	12,12,12,12,12,12	56, 62, 62	12,36,42,62,12,12
Pencere süresi	20,50,100,200,400,600	600,600,400	20,600,600,100,400,600

En yüksek doğruluk KNN sınıflandırıcı k parametresi 3 olarak alındığında hesaplanmıştır. Bu durumda Mel-filtre, öznitelik sayısı ve pencere süresi sırasıyla 64-56-600, 74-62-600 ve 74-62-400 olduğu MFCC uygulamalarında en yüksek doğruluk elde edilmiştir. Öznitelik sayısının az olması sınıflandırıcı zaman/performans açısından daha iyi olacağı için Mel-filtre sayısı 64, öznitelik sayısı 56 ve pencere süresi 600 ms olan MFCC uygulaması seçilmiştir. Bu analiz sonucundan sonra ilk akla gelen “56 öznitelik sayısının fazla olması ve bu özniteliklerde gereksiz veri olabileceği için, ayırt edici en iyi öznitelikler hangisidir?” sorusudur.

İlerleyen bölümlerde aksi belirtilmedikçe en iyi performans gösteren Mel-filtre sayısı 64, öznitelik sayısı 56 ve pencere süresi 600 olan MFCC uygulaması kullanılmıştır. Sınıflandırıcı olarak K-NN (k=3) kullanılmıştır.

4.6. Öznitelik Seçme/İndirgeme

Özniteliklerden bazıları, örneğin ait olduğu sınıfla ilgili bilgi içermiyor olabilir. Bu gereksiz özniteliklerin sınıflandırıcıya giriş olarak verilmeleri bir kazanç sağlamayacağı için, sınıflandırma işleminden önce gereksiz özniteliklerin ayıklanmaları gerekir. Sınıf bilgisini içinde barındıran ve sınıflandırıcının işini kolaylaştıran özniteliklerin bulunması ve çok yüksek boyutlu verilerin işlem süresini düşürmek için öznitelik seçme ve indirgeme yöntemleri geliştirilmiştir. Bu çalışmada öznitelik seçmek için Entropi Ölçütü, Fisher Farklılık Oranı (FDR) ve Öznitelik vektör histogram gibi yöntemler kullanılmıştır. Öznitelik indirgeme için Temel Bileşenler Analizi (PCA) ve Doğrusal Ayrışım Analizi (LDA) yöntemleri kullanılmıştır [53].

4.6.1. Öznitelik Seçme

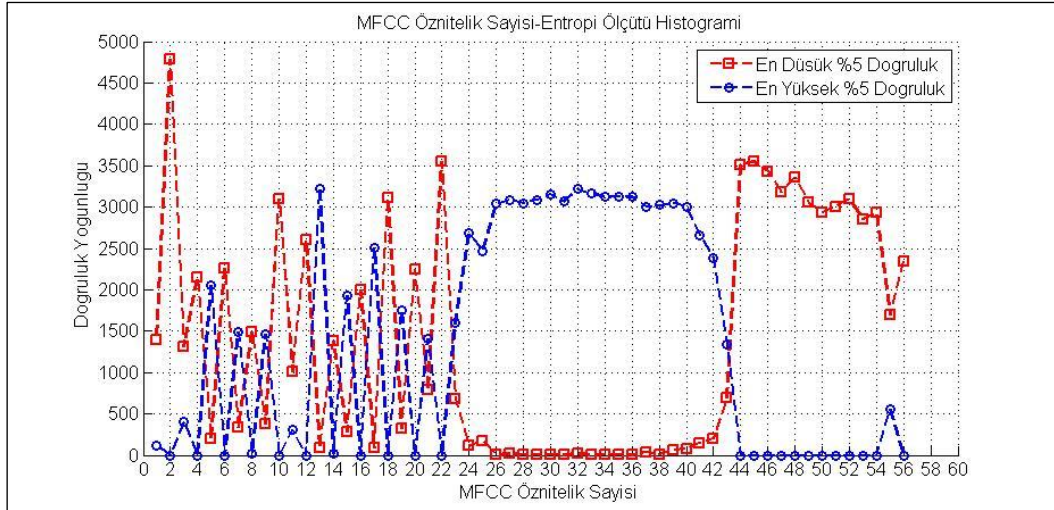
Bu bölümde öznitelik seçmek için Entropi Ölçütü, Fisher Farklılık Oranı(FDR) ve Öznitelik vektör histogram gibi yöntemler incelenmiştir.

- Entropi Ölçütü

Entropi ölçütü özniteliğin içindeki bilgiyi kullanarak seçim yapar. Bu nedenle öznitelik bir dağılım gibi ele alınıp, entropisi hesaplanır. Entropi ölçütü arttıkça sınıfların birbirinden ayırt edilebilmesinin arttığı kabul edilir [44], [53].

MFCC imlementasyonu sonucu bulunan özniteliklerin birli, ikili, üçlü, ve dördü kombinasyonlar halinde entropi ölçütü hesaplanmıştır. Elde edilen entropi ölçütleri küçükten büyüğe sıraya dizilmiştir. En düşük entropi ölçütüne sahip %5'lik kısım ile en yüksek entropi ölçütüne sahip %5'lik kısımdaki MFCC özniteliklerinin histogramlarına bakılmıştır. Bu sayede entropi ölçütünün düşük olmasını ve yüksek olmasını sağlayan MFCC öznitelikler hangileri olduğu gözlemlenmiştir.

MFCC özniteliklerin birer, ikişer, üçer ve dörder kombinasyonları sonucu elde edilen entropi ölçütünün en düşük ve en yüksek %5'lik kısımlarının MFCC öznitelik histogramları Şekil 4.5'te gösterilmiştir.



Şekil 4.5: MFCC öznitelikleri ve Entropi ölçütü histogramı.

Şekil 4.5'te görüldüğü gibi entropi ölçütü yüksek kısmı oluşturan MFCC öznitelikleri 5, 7, 9, 13, 15, 17, 19, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42'dir.

Bu gözlem sonucu ilk akla gelen 'Peki Entropi ölçütü sonucu elde edilen bu MFCC özniteliklerin kombinasyonlarının sınıflandırıcı başarı oranları nedir?' sorusudur. Bunun için bu özniteliklerin kendi aralarında kombinasyonları oluşturularak K-NN sınıflandırıcıya giriş olarak verilmiştir. K-NN sınıflandırıcı performans Tablo 4.5'teki gibi gözlemlenmiştir.

Tablo 4.5: Entropi ölçütünde MFCC özniteliklerin K-NN performansları.

MFCC Öznitelikler	K-NN Performansı
5-7-9-17-24-25-26-27-30	%78.1
5-7-9-15-17-24-25-27	%77.8
7-9-15-17-19-24-25-29-30	%77.8
7-9-15-17-19-24-25-28-29-30	%77.8

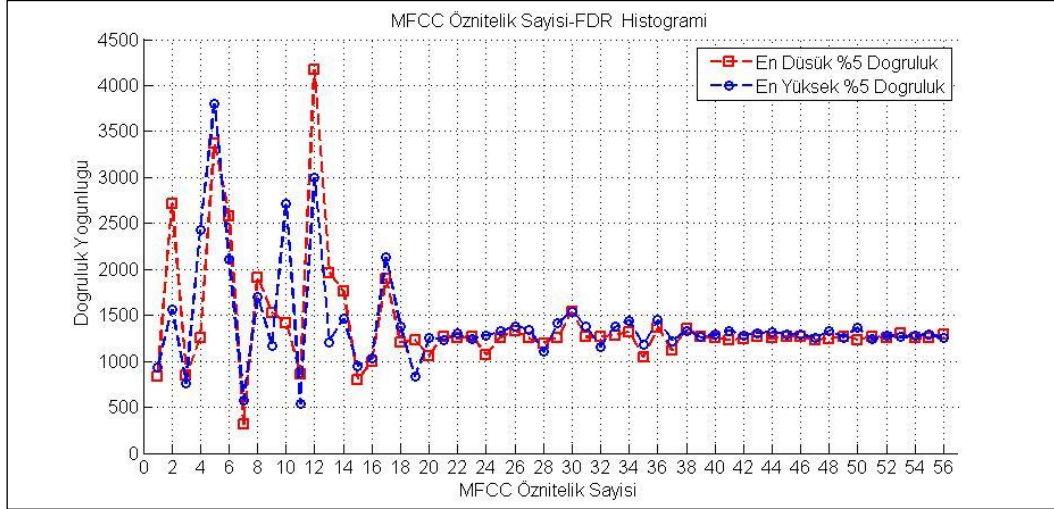
MFCC uygulamasının tüm öznitelikleri kullanıldığı zaman elde edilen performans %79.8'dir. Tablo 4.5'te görüldüğü gibi Entropi ölçütü sonucu MFCC özniteliklerinden 5-7-9-17-24-25-26-27-30 kullanıldığı zaman %78.1 performans elde edilmiştir. Bu sonuç tüm özniteliklerin kullanıldığı zamanki performanstan daha iyi olmadığı gözlemlenmiştir.

- Fisher Farklılık Oranı

Sınıfları birbirinden ayırmanın kullanışlı ölçülerinden biri de Fisher farklılık oranıdır. MFCC uygulamasında 56 öznelik mevcuttur. Bu özneliklerden hangilerinin sınıfları ayırt etme bilgisine daha çok sahip olduğunu bulmak için FDR oranı gözlemlenmiştir.

MFCC imlementasyonu sonucu bulunan öznelikler birli, ikili, üçlü ve dörtlü, kombinasyonlar halinde FDR'si hesaplanmıştır. Elde edilen FDR küçükten büyüğe sıraya dizilmiştir. En düşük FDR'ye sahip %5'lik kısım ile en yüksek FDR'ye sahip %5'lik kısımdaki MFCC özneliklerinin histogramlarına bakılmıştır. Bu sayede FDR oranının düşük olmasını ve yüksek olmasını sağlayan MFCC öznelikler hangileri olduğu gözlemlenmiştir.

MFCC özneliklerin birer, ikişer, üçer ve dörder kombinasyonları sonucu elde edilen FDR oranının en düşük ve en yüksek %5'lik kısımlarının MFCC öznelik histogramları Şekil 4.6'da gösterilmiştir.



Şekil 4.6: MFCC öznelikleri ve FDR oranı histogramı.

Şekil 4.6'da görüldüğü gibi FDR oranının yüksek kısmını oluşturan MFCC öznelikleri 1, 2, 4, 5, 7, 10,15, 17, 20, 24 olduğu gözlemlenmiştir. Bu MFCC özneliklerinin kendi aralarında kombinasyonları K-NN sınıflandırıcıya giriş olarak verilmiştir. Performans oranları Tablo 4.6'da gösterilmiştir.

Tablo 4.6: FDR oranından elde edilen MFCC özniteliklerin K-NN performansları.

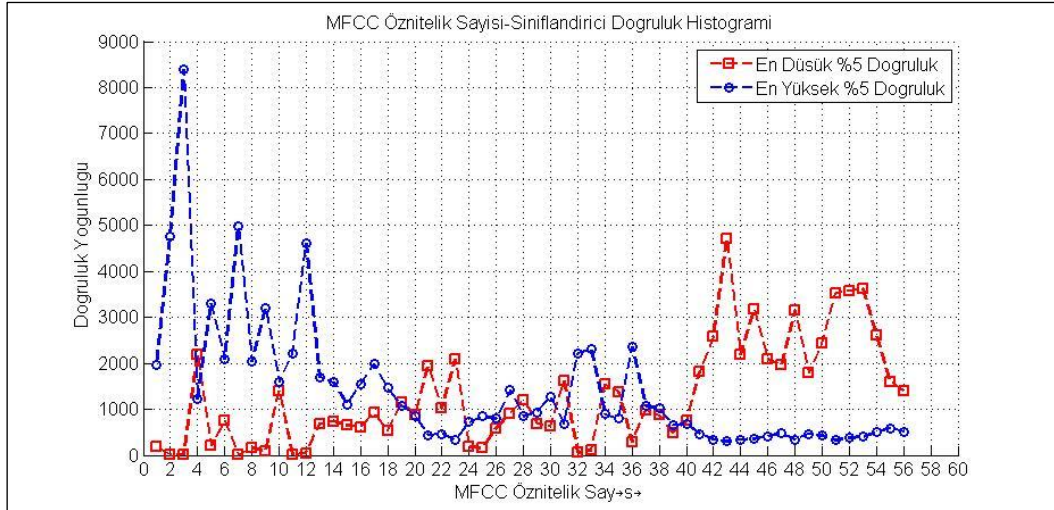
MFCC Öznitelikler	K-NN Performansı
1-4-5-7-10-17-20-24	%76.8
1-2-4-5-7-17-20-24	%76.5
1-2-4-5-7-17-20	%76
1-4-5-7-10-20-24	%76

MFCC uygulamasının tüm öznitelikleri K-NN sınıflandırıcısına giriş olarak verildiğinde %79.8 performans elde edilmiştir. Entropi ölçütü sonucu elde edilen MFCC özniteliklerinde maksimum %78.1 performans elde edilmiştir. FDR oranına göre yapılan MFCC öznitelikleri seçme işleminde elde edilen öznitelikler kombinasyonunda maksimum performans %76.8 elde edilmiştir.

- Öznitelik Vektör Histogramı

En iyi performans gösteren MFCC uygulaması 56 özniteliğe sahiptir. Ancak bu 56 öznitelik arasında bir sinyaldeki gürültü gibi bazı gereksiz veriler bulunabilmektedir. Bu gereksiz veriler sınıflandırıcıda hesaplamalara dâhil edildiğinden dolayı doğruluk oranını düşürmektedir. Bundan dolayı 56 öznitelik içinde en iyi MFCC öznitelikleri seçilerek sınıflandırıcıya giriş olarak verilirse doğruluk oranı artabilir düşüncesi ile tüm MFCC öznitelikleri birer, ikişer, üçer ve dörder gruplar halinde K-NN sınıflandırıcısına giriş olarak verilmiştir. Sınıflandırıcı doğruluk sonuçları küçükten büyüğe sıraya dizilmiştir. En düşük doğruluk oranına sahip %5'lik kısım ile en yüksek doğruluk oranına sahip %5'lik kısımdaki MFCC öznitelikler histogramı incelenmiştir. Bu sayede sınıflandırıcı doğruluk oranının en yüksek olduğu %5'lik kısımdaki özniteliklerin yoğunluğu ölçülmüştür.

MFCC özniteliklerin birer, ikişer, üçer ve dörder kombinasyonları sonucu elde edilen K-NN doğruluk oranının en düşük ve en yüksek %5'lik kısımlarının MFCC öznitelik histogramları Şekil 4.7'de gösterilmiştir.



Şekil 4.7: MFCC öznitelik sayısı ve K-NN doğruluk histogramı.

Şekil 4.7’de gösterildiği gibi K-NN sınıflandırıcı doğruluk oranının yüksek olmasını sağlayan MFCC öznitelikleri 1, 2, 3, 5, 6, 7, 8, 9, 11, 12, 13, 14, 17, 18, 32, 33, 36 olduğu gözlemlenmiştir. Bu özniteliklerin kendi aralarında kombinasyonları oluşturularak K-NN sınıflandırıcıya giriş olarak verilmiştir. K-NN sınıflandırıcı performansları Tablo 4.7’de gösterilmiştir.

Tablo 4.7: Öznitelik vektör histogramına göre en yüksek K-NN performansları.

MFCC Öznitelikleri	K-NN Performansı
1-3-6-7-8-9-13-14-17-33	%81.8
1-3-5-6-7-9-11-13-14-17-36	%81.8
1-3-6-7-9-11-13-14-17-33-36	%81.6
1-3-6-7-9-11-13-14-17-36	%81.5

MFCC uygulamasının tüm öznitelikleri K-NN sınıflandırıcısına giriş olarak verildiğinde %79.8 performans elde edilmiştir. Entropi ölçütü sonucu elde edilen MFCC özniteliklerinde maksimum %78.1 performans elde edilmiştir. FDR oranına göre yapılan MFCC öznitelikleri seçme işleminde elde edilen öznitelikler kombinasyonunda maksimum performans %76.8 elde edilmiştir. Öznitelik vektör histogram yönteminde %81.8 oranında maksimum performans elde edilmiştir.

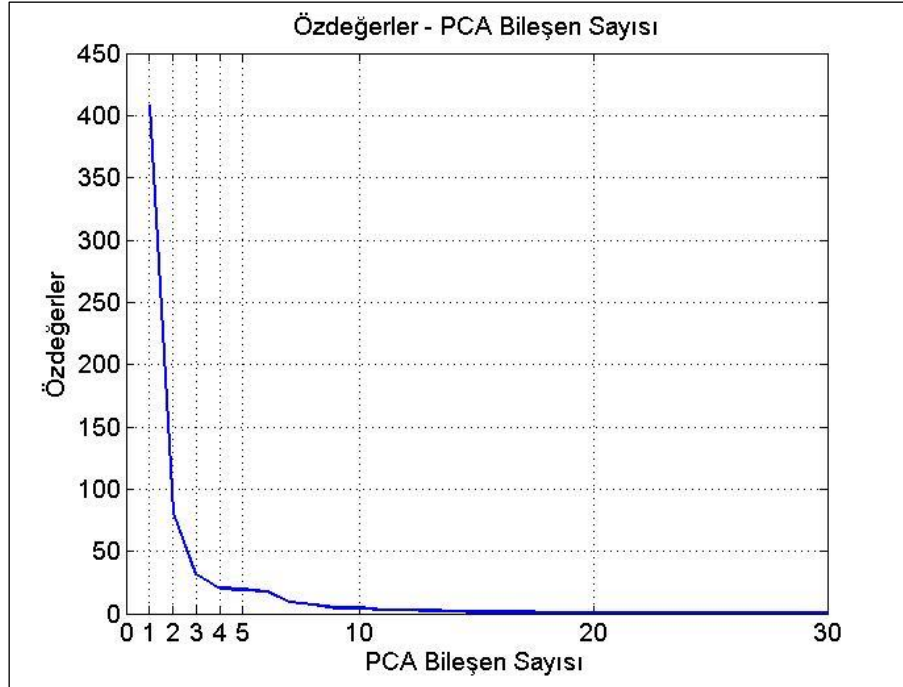
4.6.2. Öznitelik İndirgeme

Bu bölümde öznitelik indirgeme için Temel Bileşenler Analizi (PCA) ve Doğrusal Ayrışım Analizi (LDA) yöntemleri incelenmiştir.

- Temel Bileşenler Analizi

Temel Bileşenler Analizinde yüksek doğrulukta, az bileşen ile gerçek veriyi temsil etme yöntemidir. Temel Bileşenler Analizi yöntemi kullanılarak öznitelik indirgeme gerçekleştirilmiştir.

56 öznitelige sahip olan MFCC uygulaması en yüksek performans oranı vermiştir. Eğitim seti Temel Bileşenler Analizine giriş olarak verildiğinde 56 bileşenli bir eğitim seti elde edilmiştir. Bu bileşenler ilk sıradan itibaren önemlilik derecesine göre sıralanmıştır. Bu bileşenlerden ilk sıradan başlanarak veriyi en iyi temsil edecek şekilde belli miktarı alınması gereklidir. Bundan dolayı özdeğer (eigenvalue) – PCA bileşen grafiğinden yararlanılarak PCA bileşen miktarı belirlenmiştir.



Şekil 4.8: Özdeğer (Eigenvalue) – PCA bileşen sayısı.

Şekil 4.8’de görüldüğü gibi öz değer PCA bileşen sayısı 1-2-3-4’te yüksek değerlere sahip olduğu ve PCA bileşen sayısı 4’ten sonra keskin bir iniş yapmamış ve aynı öz değere sahip olacak şekilde devam ettiği gözlemlenmiştir.

Bundan dolayı PCA bileşenlerinden 1-4 arası K-NN sınıflandırıcıya giriş olarak verildiği zaman %63.5 oranında performans elde edilmiştir.

- Doğrusal Ayrışım Analizi

Doğrusal Ayrışım Analizi sınıf ayırımında kullanılan bilgiyi daha çok koruyan boyut indirgeme yöntemidir. LDA bilgiler arasındaki varyansı azaltırken, PCA varyansı korumaktadır. Ancak PCA sınıf ayırt ediciliği düşürürken, LDA sınıf ayırt ediciliği korumakta ve yükseltebilmektedir.

MFCC uygulaması sonucu elde edilen 56 öz nitelikli eğitim seti LDA ile 5 boyuta indirgenmiştir. LDA ile elde edilen 5 boyutlu eğitim seti K-NN sınıflandırıcıya giriş olarak verildiğinde %76.3 doğruluk elde edilmiştir.

- Öznitelik Seçme/İndirgeme Sonuçları

Tablo 4.8’de gösterildiği gibi öznitelik indirgeme yöntemlerinden Doğrusal Ayrışım Analizi yöntemi, Temel Bileşenler Analizi yöntemine göre daha çok sınıf ayırıştırma bilgisini koruyarak boyut indirgemesi gerçeklemiştir.

Tablo 4.8: Öznitelik seçme/indirgeme yöntemleri K-NN performansları.

Öznitelik Seçme/İndirgeme	Yöntemler	K-NN Performansı
Öznitelik Seçme	Entropi Ölçütü	%78.1
	FDR Oranı	%76.8
	Öznitelik Vektör Histogramı	%81.8
Öznitelik İndirgeme	Temel Bileşenler Analizi(PCA)	%63.5
	Doğrusal Ayrışım Analizi(LDA)	%76.3

Öznitelik seçme yöntemlerinden öznitelik vektör histogram yöntemi MFCC özniteliklerini kombinasyonlar halinde K-NN sınıflandırıcıya giriş olarak vermiştir. En yüksek doğruluk oranını veren kombinasyon bulunarak öznitelik seçme

yöntemlerinden en yüksek performans Öznitelik vektör histogramı ile elde edilmiştir.

4.7. Hava Koşulları Dikkate Alındığında

Bu çalışmaya başlarken Hipotez bölümünde hava koşulları dikkate alındığında trafik yoğunluğu tespiti başarı oranının artabileceği ileri sürülmüştü ve Bölüm 3'te yağmurlu hava koşullarındaki akustik sinyallerin spektrumları incelenmiş ve bu spektrumlar hipotezin olabileceğini göstermiştir. Bu aşamada hava koşulları dikkate alınmadan elde edilen en iyi MFCC uygulaması, hava koşulları dikkate alınarak elde edilen yağmurlu ve yağmursuz veri setinde uygulanmıştır. Analiz sonuçları Tablo 4.9'da gösterilmiştir.

Önceki bölümlerde Hava koşulları dikkate alınmadan Mel-filtre sayısı 64, öznitelik sayısı 56, pencere süresi 600-300 ms olduğu MFCC uygulamasında en yüksek performans elde edilmişti. Öznitelik seçme bölümünde en iyi performansı gösteren MFCC öznitelikleri Tablo 4.9'ad gösterildiği gibi seçilmiştir.

Tablo 4.9: Hava koşulları dikkate alınmadığında en yüksek K-NN performansları.

MFCC Öznitelikleri	K-NN Performansı
1-3-6-7-8-9-13-14-17-33	%81.8
1-3-5-6-7-9-11-13-14-17-36	%81.8
1-3-6-7-9-11-13-14-17-33-36	%81.6
1-3-6-7-9-11-13-14-17-36	%81.5

Tablo 4.9'da gösterilen en yüksek performanstaki MFCC öznitelik kombinasyonları , hava koşulları dikkate alınarak K-NN sınıflandırıcıya giriş olarak verilmiştir. Bu analizde yağmurlu hava koşulunda elde edilen sonuçlar Tablo 4.10'da, yağmursuz hava koşulunda elde edilen sonuçlar Tablo 4.11'de gösterilmiştir.

Tablo 4.10: Yağmurlu hava koşullarında en yüksek K-NN performansları.

MFCC Öznitelikleri	K-NN Performansı
1-3-6-7-8-9-13-14-17-33	%90.1
1-3-5-6-7-9-11-13-14-17-36	%84
1-3-6-7-9-11-13-14-17-33-36	%87
1-3-6-7-9-11-13-14-17-36	%87

Tablo 4.10’da gösterildiği gibi MFCC özniteliklerinden 1, 3, 6, 7, 8, 9, 13, 14, 17, 33 kombinasyonu yağmurlu hava koşullarında %90.1 performans göstermiştir.

Tablo 4.11: Yağmursuz hava koşullarında en yüksek K-NN performansları.

MFCC Öznitelikleri	K-NN Performansı
1-3-6-7-8-9-13-14-17-33	%79.5
1-3-5-6-7-9-11-13-14-17-36	%81.6
1-3-6-7-9-11-13-14-17-33-36	%81
1-3-6-7-9-11-13-14-17-36	%81

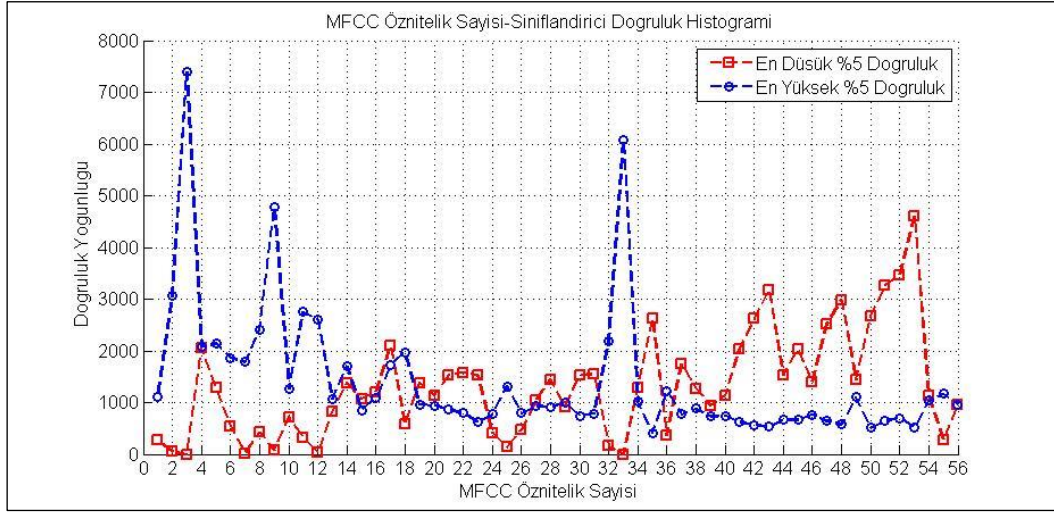
Hava koşulları dikkate alınmadan elde edilen en yüksek performans sonucunu gösteren MFCC uygulamasına ait seçilen öznitelikler, hava koşulları dikkate alındığında K-NN sınıflandırıcıya giriş olarak verilmesi sonucu yağmurlu hava koşullarında yüksek performans gösterirken, yağmursuz hava koşullarında hava koşulları dikkate alınmadığında elde edilen ile yakın performans göstermiştir.

Bu noktada akla gelen ilk soru “yağmurlu ve yağmursuz durum için öznitelik vektör histogram yöntemi kullanılarak seçilen iki farklı öznitelik kombinasyonunun performansları, son elde edilen performans değerlerinden yüksek olup olmaması?” Bundan dolayı hava koşulları dikkate alındığı zaman en iyi performansı veren öznitelikleri bulmak için çalışmalar yapılmıştır.

4.7.1. Yağmurlu Hava Koşullarına Göre Öznitelik Seçimi

Hava koşulları dikkate alınmadığı durumda öznitelik seçiminde en iyi performans Öznitelik vektör histogram yöntemi ile elde edilmiştir. Bu bölümde de

aynı yöntem ile yağmurlu hava koşullarına göre öznelik seçimi yapılmıştır. İlk olarak yağmurlu hava koşulları ile oluşturulan veri seti öznelik vektör histogram yöntemi kullanılarak K-NN sınıflandırıcı performansları hesaplanmıştır. Elde edilen doğruluk oranlarının en yüksek ve en düşük doğrulukları oluşturan %5'lik kısımdaki özneliklerin histogram grafiği Şekil 4.9'da gösterilmiştir.



Şekil 4.9: Yağmurlu hava öznelikler ve K-NN doğruluk histogramı.

Şekil 4.9'da gösterildiği gibi 1, 2, 3, 6, 7, 8, 9, 10, 11, 12, 18, 25, 32, 33 numaralı özneliklerde yüksek doğruluk yoğunluğu daha fazla olduğu gözlemlenmiştir.

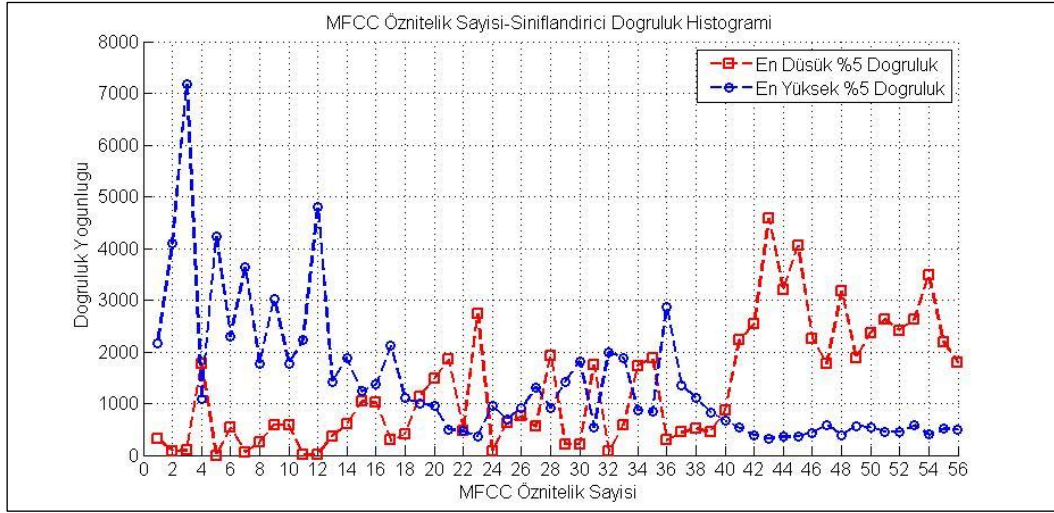
Yüksek doğruluk oranına sahip %5'lik kısımdaki özneliklerin tüm grup kombinasyonları K-NN sınıflandırıcıya giriş olarak verilmiştir. Elde edilen sonuçlar Tablo 4.12'de gösterilmiştir.

Tablo 4.12: Yağmurlu hava koşullarına göre özneliklerin K-NN performansları.

MFCC Öznelikleri	K-NN Performansı
1-2-3-6-10-11-25-33	%90.1
1-2-3-6-8-10-11-25-33	%90.1
1-2-3-6-8-9-10-11-25-32	%90.1

4.7.2. Yağmursuz Hava Koşullarına Göre Öznitelik Seçimi

Hava koşulları dikkate alınmadığında elde edilen MFCC uygulaması ve seçilen öznitelikler, yağmursuz hava koşullarında elde edilen veri seti ile test edildiğinde performans artışı olmamıştı. Bundan dolayı yağmursuz hava koşulları ile yeni öznitelik seçmek için analizler yapılmıştır. İlk olarak yağmursuz hava koşullarında oluşturulan veri seti ile öznitelikler 1-2-3-4'lü gruplar halinde K-NN sınıflandırıcıya giriş olarak verilmiştir. Elde edilen doğruluklardan en yüksek doğrulukta yer alan %5'lik kısım ile en düşük doğrulukta yer alan %5'lik kısmın histogramı Şekil 4.10'da gösterilmiştir.



Şekil 4.10: Yağmursuz hava öznitelikler ve K-NN doğruluk histogramı.

Tablo 4.13: Yağmursuz hava koşullarına göre özniteliklerin K-NN performansları

MFCC Öznitelikleri	K-NN Performansı
1-3-5-7-9-10-17-29-36	%81.4
3-5-7-9-17-30-36	%80.8
5-6-7-9-10-12-30	%80.8

Yağmursuz hava koşullarına göre öznitelik vektör histogramı sonucu seçilen öznitelik kombinasyonunun performansı ile hava koşulları dikkate alınmadığı durumda seçilen öznitelik kombinasyonunun performansı yaklaşık aynı çıkmıştır.

5. SONUÇ ve GELECEK ÇALIŞMALAR

Günümüze kadar trafik yoğunluğu tespiti ile ilgili birçok çalışma yapılmıştır. Bu çalışmalarda manyetik detektör, hızölçer, ultrasound, radar, lazer ve görüntü gibi sensörler kullanılmıştır. Bu sensörlerden bazılarının kurulumları ve destekleri çok maliyetli olmasının yanında aynı zamanda kurulum ve destek esnasında trafik akışına engel olmasından dolayı geniş çaplı uygulanabilirliğe sahip değildir. Bundan dolayı son on yılda akustik sinyal ile trafik yoğunluğu tespiti üzerine çalışmalar artmıştır.

Bu çalışmada, hava koşulları aynı olan günlerde ve şehir içinde toplanan veri seti üzerinde test edildiğinde %98-100 başarı elde edildiği literatürde raporlanmış olan bir algoritma, hava koşulları farklı günlerde ve E-5 karayolu üzerinde farklı noktalarda toplanan veri seti ile test edildiğinde %64-68 aralığında bir performans sağlamıştır. Şehir içinde toplanan ilk veri setinde trafiğin yoğun olduğu zamanlarda korna sesinin yoğunlukta olması akustik sinyalin ayırt ediciliğini artırmakta iken E-5 karayolunda toplanan veride ise korna sesinin az olması ve verinin farklı hava koşullarında toplanması ayırt ediciliği olumsuz etkilemiş ve performans oranını düşürmüştür.

Bu çalışmada, yol kenarından toplanan akustik ses verisi ile trafik yoğunluğu tespitinin hava koşullarının dikkate alınmasıyla performans artışının olacağı gösterilmiştir. Bu kapsamda yapılan çalışmalar sırasıyla ve özet olarak aşağıda sıralanmıştır:

Öznitelik olarak MFCC kullanılmış ve MFCC parametreleri için optimal değerler bulunarak hava koşulları dikkate alınmadan tüm veri seti trafik yoğunluğu tespit performansı %64-68 aralığından yaklaşık %80'e çıkartılmıştır.

Önerilen öznitelik vektör histogram yöntemi ile öznitelik seçme işlemi yapılarak performans yaklaşık %82'ye ulaşmıştır.

Hava koşulları dikkate alınmış, yağmurlu ve yağmursuz havada toplanan veriler için ayrı sınıflandırma modelleri oluşturulmuş, yağmurlu havada trafik yoğunluğu tespiti performansı %90, yağmursuz havada trafik yoğunluğu tespiti performansı ise %81 elde edilmiştir. E-5 kara yoluna ait veri seti üzerinde hava koşulları dikkate alındığı zaman trafik yoğunluğu ortalama %85 doğrulukla tespit edilebilmiştir.

Bu alıřmada yađmurlu ve yađmursuz hava řartlarında sınıflandırma performansını iyileřtirmeye yönelik model geliřtirme ve analiz alıřması yapılmıřtır. İleriye dnk bir alıřmada, rzgr hızı ve sıcaklık gibi diđer parametrelerin de modele dahil edilmesinin performansa etkisi ele alınabilir.

KAYNAKLAR

- [1] Tyagi V., Kalyanamaran S., Krishnapuram R., (2012), "Vehicular traffic density state estimation based on cumulative road acoustics", IEEE Transactions on Intelligent Transportation Systems, 13 (3), 1156-1166.
- [2] Borkar P., Malik L., (2013), "Acoustic signal based traffic density state estimation using SVM", I.J. Image, Graphics and Signal Processing, 5 (8), 37-44.
- [3] Borkar P., Malik L., (2013), "Review on vehicular speed, density estimation and classification using acoustic signal", International Journal for Traffic and Transport Engineering, 3 (3), 331-343.
- [4] Sen R., Siriah P., Raman B., (2011), "RoadSoundSense: Acoustic sensing based road congestion monitoring in developing regions", Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks, 125-133, Salt Lake City UT, 27-30 June.
- [5] Kato J., Watanabe T., Joga S., Liu Y., Hase H., (2004), "An HMM/MRF-based stochastic framework for robust vehicle tracking", IEEE Transactions on Intelligent Transportation Systems, 5 (3), 142-154.
- [6] Jazayeri A., Cai H., Zheng J., Tuceryan M., (2011), "Vehicle detection and tracking in car video based on motion model", IEEE Transactions on Intelligent Transportation Systems, 12 (2), 583-595.
- [7] Kwong K., Kavalier R., Rajagopal R., Varaiya P., (2010), "Real-Time measurement of link vehicle count and travel time in a road network", IEEE Transactions on Intelligent Transportation Systems, 11 (4), 814-825.
- [8] Zhank W., Wu M., Xiaokang Y., Xiangzhong F., (2008), "Multilevel framework to detect and handle vehicle occlusion", IEEE Transactions on Intelligent Transportation Systems, 9 (1), 161-174.
- [9] Faro A., Giardona D., Spampinato C., (2008), "Evaluation of the traffic parameters in a metropolitan area by fusing visual perceptions and CNN processing of webcam images", IEEE Transactions on Intelligent Transportation Systems, 19 (6), 1108-1129.
- [10] Robertson D., Bretherton R., (2008), "Optimizing networks of traffic signals in real time-the SCOOT method", IEEE Transactions on Intelligent Transportation Systems, 40 (1), 11-15.
- [11] Coifman B., Cassidy M., (2002), "Vehicle reidentification and travel time measurement on congested freeways", Transportation Research Part A: Policy and Practice, 36 (10), 899-917.

- [12] Chen S., Sun P., Bridge B., (2001), "An traffic monitoring using digital sound field mapping", *IEEE Transactions on Vehicular Technology*, 50 (6), 1582-1589.
- [13] Barbagli B., Manes G., Facchini R., (2012), "Acoustic sensor network for vehicle traffic monitoring", In *Proceedings of the 1st International Conference on Advances in Vehicular Systems, Technologies and Applications*, 1-6, Venice Italy, 24-29 June.
- [14] Bhave N., Rao P., (2011), "Vehicle engine sound analysis applied to traffic congestion estimation", In *Proc. of International Symposium on CMMR and FRSM*, Utkal University Bhubaneswar India, 9-12 March.
- [15] Rajendra C., Kulkarni P., (2010), "Road traffic estimation using In-situ acousting sensing", *ACM SIGCOMM Computer Communication Review*, 41 (4), 431-432.
- [16] Joshi V., Rajamani N., Prathapaneni N., Subramaniam L., (2013), "Traffic density state estimation based on acoustic fusion", In *Acoustics, Speech and Signal Processing (ICASSP)*, 478-482, Vancouver, BC, 26-31 May.
- [17] Kato J., (2005), "An attempt to acquire traffic density by using road traffic sound", *Active Media Technology*, 353-358.
- [18] Amman S., Das M., (2001), "An efficient technique for modeling and synthesis of automotive engine sounds", *IEEE Transactions on Industrial Electronics*, 48 (1), 225-234.
- [19] Borkar P., Malik L., (2013), "Cumulative acoustic signal based traffic density state estimation", *Third International Conference on Advances in Computing and Communications*, 169-172, Cochin, 29-31 August.
- [20] Arora A., Dutta P., Bapat S., Kulathumani V., Zhang H., Naik V., Mittal V., Cao H., Demirbas M., Gouda M., Choi Y., Herman T., Kulkarni S., Arumugam U., Nesterenko M., Vora A., Miyashita M., (2004), "A line in the sand: a wireless sensor network for target detection, classification and tracking", *Computer Networks*, 46 (5), 605-634.
- [21] Koch W., Koller J., Ulmke M., (2006), "Ground target tracking and road map extraction", *Transportation ISPRS Journal of Photogrammetry and Remote Sensing*, 61 (3), 197-208.
- [22] Ding J., Cheung S., Tan C., Varaiya P., (2004), "Signal processing of sensor node data for vehicle detection", In *Proceedings of the 7th international IEEE Conference on Intelligent Transportation System*, 70-75, 3-6 October.
- [23] Ploetner J., Trivedi M., (2006), "A multimodal framework for vehicle and traffic flow analysis", In *IEEE Intelligent Transportation Systems Conference*, 1507-1512, Toronto, Ont., 17-20 September.

- [24] Kaewkamnerd S., Chinrungrueng J., Pongthornseri R., Dumnin S., (2010), "Vehicle Classification Based on Magnetic Sensor Signal", Information and Automation (ICIA), IEEE International Conference, 935-939, Harbin/China, 20-23 June.
- [25] Mapps D., (1997), "Magnetoresistive sensors", Sensors and Actuators A: Physical, 59 (1), 9-19.
- [26] Nooralahiyan A., Dougherty M., McKeown D., Kirby H., (1997), "A field trial of acoustic signature analysis for vehicle classification", Transportation Research Part C:Emerging Technology, 5 (3), 165-177.
- [27] Sun Z., Bebis G., Miller R., (2006), "On-road vehicle detection: a review", IEEE Transactions on Pattern Analysis and Machine Intelligence, 28 (5), 694-711.
- [28] Hinz S., Stilla U., (2006), "Car detection in aerial thermal images by local and global evidence accumulation", IEEE Pattern Recognition Letters, 27 (4), 308-315.
- [29] Wilson J., (2005), "Sensor Technology Handbooks", 1st Edition, Elsevier Inc..
- [30] Atal B., Rabiner L., (1976), "A pattern recognition approach to voiced-unvoiced-silence classification with applications to speech recognition", IEEE Transactions on Acoustics, Speech and Signal Processing, 24 (3), 201-212.
- [31] Evans N., (2010), "Automated vehicle detection and classification using acoustic and seismic signals", Yüksek Lisans Tezi, University of York.
- [32] Wang X., Qi H., (2002), "Acoustic target classification using distributed sensor arrays", Proc. IEEE ICASSP, 4, 4186-4189.
- [33] Sen R., Sharma R., Sharma P., (2010), "Horn-ok please", Proceedings of the 8th international conference on Mobile systems, applications, and services ACM, 137-150, New York USA, 15 June.
- [34] Amman S., Das M., (2001), "An efficient technique for modeling and synthesis of automotive engine sounds", IEEE Transactions on Industrial Electronics, 48 (1), 225-234.
- [35] Sandberg U., (2001), "Tyre/road noise - myths and realities", The International Congress and Exhibition on Noise Control Engineering, 35-56, The Hague, 27-30 August.
- [36] Eskridge R., Hunt J., (1979), "Highway modeling.Part I: Prediction of velocity and turbulence fields in the wake of vehicles", Journal of Applied Meteorology, 18 (4), 387-400.

- [37] Wang L., (2008), "A study on hands-free speech/speaker recognition", Doctor's Thesis, Toyohashi University of Technology.
- [38] Furui S., (1989), "Digital speech processing, synthesis and recognition", 1st Edition, Marcel Dekker.
- [39] Reynolds D. A., Rose R.C., (1995), "Robust text-independent speaker identification using gaussian mixture speaker models", IEEE Trans. Speech Processing, 3 (1), 72-83.
- [40] Campbell J. P., (1997), "Speaker recognition: a tutorial", Proceedings of the IEEE, 85 (9), 1437-1462.
- [41] Davis S. B., Mermelstein P., (1980), "Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences", Speech and Signal Processing, IEEE Transactions on Acoustics , 28 (4), 389-397.
- [42] Madiseti V.K., (2010), "The Digital Signal Processing Handbook", 2nd Edition, CRC Press.
- [43] Yin M., Zhang H., Meng H., Wang X., (2007), "An HMM-based algorithm for vehicle detection in congested traffic situations", Intelligent Transportation Systems Conference, 736-741, Seattle, WA, 30 September - 3 October.
- [44] Terano T., Lui H., Chen A., (2000), "Knowledge discovery and data mining ", 4th Pacific-Asia Conference, PAKDD 2000 Kyoto, Japan, 18-20 April.
- [45] Özkan Y., (2013), "Veri Madenciliği Yöntemleri", 2.Baskı, Papatya Yayıncılık Eğitim.
- [46] Silahtaroglu G., (2013), "Veri Madenciliği Kavram ve Algoritmaları", 2.Baskı, Papatya Yayıncılık Eğitim.
- [47] Picone J., (1993), "Signal modeling techniques in speech recognition" Proceeding of the IEEE, 81 (9), 1215-1247.
- [48] Kato J., Hiramatsu Y., Watanabe T., (2004), "Estimating traffic density using sounds of moving vehicles", In Proceedings of the Seventh Eurographics conference on Multimedia, 21-29, Eurographics Association.
- [49] Karpov E., (2003), "Real-time speaker identification", Master's Thesis, University of Joensuu.
- [50] Kinnunen T., (2003), "Spectral features for automatic text-independent speaker recognition", Licentiate's Thesis, University of Joensuu.
- [51] Karpov E., (2003), "Real-time speaker identification", Master's Thesis, University of Joensuu.

- [52] Cladio B., Ricotti L. P., (1999), "Speech recognition theory and C++ implementation", 1st Edition, John WILEY&Sons, Ltd.
- [53] Ünsalan C., Erçil A., (1998), "Öznitelik Seçme Yöntemlerinin Karşılaştırılması ve Başarı Kriteri", Proceedings of IEEE SIU, 60-65, Kızılcıhamam Turkey, May .

ÖZGEÇMİŞ

Fikret ÖZTÜRK 1982 yılında İstanbul'da doğdu. İlköğretimini Gebze'de tamamladıktan sonra 1996 yılında Vehbi Dinçerler Fen Lisesi'ne başladı. Lise eğitiminden sonra 1999 yılında İstanbul Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği bölümüne başladı. 2003 yılında lisans eğitimini başarıyla tamamladıktan sonra beş yıl özel sektörde biyomedikal teknolojileri üzerine AR-GE çalışmaları yaptı. 2009 yılında TÜBİTAK Bilişim Teknolojileri Enstitüsü'nde Gerçek Zamanlı İşletim Sistemleri konusunda çalışan ekipte araştırmacı olarak işe başladı. Aynı yıl Gebze Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. Fikret ÖZTÜRK halen TÜBİTAK, Bilişim Teknolojileri Enstitüsü'nde Gerçek Zamanlı İşletim Sistemleri ve İnsansız Hava Araçları üzerine çalışmaktadır.