

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**DOĞRUSAL TAHMİNİ KODLAMA YÖNTEMİ KULLANILARAK
TRAFİKTEKİ UYARICI SESLERİN TESPİTİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Cansu AKYÜREK ANACUR
DANIŞMAN : Doç. Dr. Rıdvan SARAÇOĞLU

VAN-2019

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**DOĞRUSAL TAHMİNİ KODLAMA YÖNTEMİ KULLANILARAK
TRAFİKTEKİ UYARICI SESLERİN TESPİTİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Cansu AKYÜREK ANACUR

VAN-2019

KABUL VE ONAY SAYFASI

Elektrik Elektronik Mühendisliği Anabilim Dalı'nda Doç. Dr. Rıdvan SARAÇOĞLU danışmanlığında, Cansu AKYÜREK ANACUR tarafından sunulan "Doğrusal Tahmini Kodlama Kullanılarak Trafikteki Uyarıcı Seslerin Tespiti" isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince 05/07/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile başarılı bulunmuş ve Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan: Doç. Dr. Rıdvan SARAÇOĞLU

İmza:

Üye: Dr. Öğr. Üyesi Murat KÖKLÜ

İmza:

Üye: Dr. Öğr. Üyesi Özkan ATAN

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 19/07/2019 tarih ve 2019/19-I sayılı kararı ile onaylanmıştır.

Doç. Dr. Serhat KARACA
Enstitü Müdür Yrd.

Enstitü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Cansu AKYÜREK ANACUR

ÖZET

DOĞRUSAL TAHMİNİ KODLAMA YÖNTEMİ KULLANILARAK TRAFİKTEKİ UYARICI SESLERİN TESPİTİ

AKYÜREK ANACUR, Cansu
Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı
Tez Danışmanı : Doç. Dr. Rıdvan SARAÇOĞLU
Temmuz 2019, 45 sayfa

Engelli bireylerin hayata katılımını sağlamak veya artırmak önemli bir sosyal konudur. Bu bağlamda, ambulans, itfaiye ve polis aracı gibi geçiş önceliği olan araçların sirenleri ve uyarı sinyallerinin tespit edilmesi işitme engellilerin trafikte daha rahat araç kullanmalarını sağlayacaktır. Bu tez çalışmasında bu tür uyarı seslerinin tanınması ve ses yönünün tespiti amaçlanmıştır. Trafikteki ambulans, polis, itfaiye gibi araçların siren sesleri uygulama için pozitif örnekler olarak nitelendirilmiştir. Müzik, trafik gürültüsü gibi sesler ise negatif sesler olarak nitelendirilip bir veri seti oluşturulmuştur. Ses sinyalleri sayısal verilere dönüştürülerek Doğrusal Tahmini Kodlama ile verinin içindeki sesi yansıtmayan nitelikler atılıp sesi en iyi yansıtan nitelikler belirlenmiştir. Temel bileşen analizi yöntemi kullanılarak veriyi en iyi temsil eden, anlamlı nitelikler çıkartılarak Destek Vektör Makineleri algoritmasıyla sınıflandırılmıştır. Ses tanıma ile ilgili model oluşturulduktan sonra yeni ses kayıtları yapılarak model test edilmiştir. Uyarıcı ses olduğu tespit edilen ses için kullanıcıya sesin yönüyle ilgili bilgi verilmesi sağlanmıştır.

Anahtar kelimeler: Destek vektör makinesi, Doğrusal tahmini kodlama, Ses sınıflandırma, Ses tanıma, Temel bileşen analizi.

ABSTRACT

DETECTING OF WARNING SOUNDS IN THE TRAFFIC USING LINEAR PREDICTIVE CODING METHOD

AKYÜREK ANACUR, Cansu
MSc. Thesis Electrical-Electronics Engineering
Supervisor : Assoc. Prof. Rıdvan SARAÇOĞLU
July 2019, 45 pages

Providing attendance of disabled persons into life and increasing it is an important social issue. In this context detecting sirens and sounds of those vehicles which have priority of way in traffic such as ambulance, fire-fighting vehicle and police car will enable to hearing disabled people to drive more comfortably. Recognising such warning sounds and detecting their direction have been aimed in this thesis. Sirens of ambulance, police car and fire-fighting vehicle in traffic have been classified as positive samples for application. Noises such as music and traffic noises have been classified as negative. Linear Predictive Coding has been made up by converting sound signals into digital data and qualities that reflect the sound in the best way has been determined by removing the qualities that do not reflect the sound in the data. By using principal component analysis method, meaningful and those qualities that represent the data in the best way have been classified by Support Vector Machine Algorithm. After creating model about sound detection, model has been tested by performing new sound records. For the sound which has been detected to be warning sound, information about the sound direction has been given to user.

Keywords: Sound recognition, Linear predictive coding, Principal component analysis, Support vector machine, Sound classification.



ÖN SÖZ

Bu tez çalışmasında, her türlü ilgi ve yardımlarını esirgemeyen danışmanım Sayın Doç. Dr. Rıdvan SARAÇOĞLU'na, hayatım boyunca benden desteklerini esirgemeyen aileme ve değerli eşim Nurullah ANACUR'a teşekkür ederim.

2019

Cansu AKYÜREK ANACUR



İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	iii
ÖN SÖZ.....	v
İÇİNDEKİLER.....	vii
ÇİZELGELER LİSTESİ	ix
ŞEKİLLER LİSTESİ	xi
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ.....	1
1.1. Tezin Amacı ve Önemi	2
2. KAYNAK BİLDİRİŞLERİ	3
3. MATERYAL VE YÖNTEM.....	7
3.1. Ham Veri Toplama	7
3.2. Öznitelik Çıkarma.....	7
3.2.1. Tanımlayıcı istatistik	8
3.2.2. Doğrusal tahmin kodlama (DTK) yaklaşımıyla öznitelik çıkarma	8
3.2.3. Hızlı fourier dönüşümü (HFD) ile öznitelik çıkarma	9
3.3. Boyut Azaltma.....	10
3.3.1. Nitelik seçimi	10
3.3.2. Nitelik çıkarımı	12
3.4. Sınıflandırma	12
3.4.1. KNN algoritması	13
3.4.2. DVM ile sınıflandırma.....	14
3.4.3. Sınıflandırma başarısının tespiti.....	15
4. BULGULAR.....	17
4.1. Ham Verinin Toplanması.....	17
4.2. Öznitelik Çıkarma.....	20
4.3. Boyut Azaltma.....	25

	Sayfa
4.3.1. Nitelik seçimi	25
4.3.2. Nitelik çıkarımı	30
4.4. Sınıflandırma	32
4.5. Ses Yönünün Belirlenmesi	33
5. TARTIŞMA VE SONUÇ	37
KAYNAKLAR	41
ÖZ GEÇMİŞ	45



ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Tanımlayıcı istatistik yöntemi ile nitelik çıkarma sonucu KNN ve DVM sınıflandırma başarıları	24
Çizelge 4.2. DTK yaklaşımı ile nitelik çıkarma sonucu KNN ve DVM sınıflandırma başarıları.....	24
Çizelge 4.3. HFD ile nitelik çıkarma sonucu KNN ve DVM sınıflandırma başarıları...	24
Çizelge 4.4. Nitelik seçme yöntemlerinin başarı oranları	30
Çizelge 4.5. DTK sonrası boyut azaltma işlemi sonucu KNN ve DVM sınıflandırma başarıları.....	31
Çizelge 4.6. HFD sonrası boyut azaltma işlemi sonucu KNN ve DVM sınıflandırma başarıları.....	32
Çizelge 4.7. KNN sınıflandırma başarıları.....	32
Çizelge 4.8. DVM sınıflandırma başarıları	33

ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 3.1. Nitelik çıkama adımları (Uğuz ve Arslan, 2010)	8
Şekil 3.2. Destek vektörleri ve düzlemler (Anonim, 2018)	14
Şekil 3.3. Karışıklık Matrisi (Coşkun ve Baykal, 2011)	15
Şekil 4.1. Sistem modeli.....	17
Şekil 4.2. Örnek bir olumlu ses sinyali	19
Şekil 4.3. Örnek bir olumsuz ses sinyali	20
Şekil 4.4. İki saniyelik bir ses sinyali	21
Şekil 4.5. Tanımlayıcı istatistik uygulanmış bir ses sinyali	22
Şekil 4.6. HFD uygulanmış örnek bir ses sinyali	23
Şekil 4.7. Aşırı öğrenme makinesi ve değişim katsayısına dayalı hızlı özellik seçimi yaklaşımı sonucu elde edilen veri seti	26
Şekil 4.8. İki mikrofonlu 51 saniyelik ses sinyali.....	34
Şekil 4.9. İki mikrofonlu 2 saniyelik ses sinyali.....	35
Şekil 4.10. Sol taraftaki mikrofona ait ses sinyali	36
Şekil 4.11. Sağ taraftaki mikrofona ait ses sinyali.....	36



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
TBA	Temel Bileşen Analizi
DVM	Destek Vektör Makineleri
DTK	Doğrusal Tahmin Kodlama
YSA	Yapay Sinir Ağları
SMM	Saklı Markov Modelleri
MFKK	Mel Frekanslı Kepstrum Katsayıları
OFA	Ortak Faktör Analizi
KMS	Kosinüs Mesafe Skorlaması
DZA	Dinamik Zaman Atlama
EKG	Elektrokardiyografi
ÇKA	Çok Katmanlı Algılayıcı
KNN	K- En Yakın Komşuluk
RTFA	Radyal Tabanlı Fonksiyon Ağları
AÖM	Aşırı Öğrenme Makinesi
DK	Değişim Katsayısı
SGÖS	Sonsuz Gizli Özellik Seçimi
İMNS	İçbükey Minimizasyon ile Nitelik Seçimi
YÖE	Yinelemeli Özellik Elemesi
EMÇSO	En Küçük Mutlak Çekme ve Seçme Operatörü
VN	Vektör Nicemleme
AFD	Ayrık Fourier Dönüşümü
HFD	Hızlı Fourier Dönüşümü



1. GİRİŞ

TÜİK'in Türkiye Sağlık araştırmasına göre 2016 yılı itibariyle Türkiye'deki 15-64 yaş arası nüfusun %12.9'u işitme engelli bireylerden oluşmaktadır (TÜİK,2016). Trafikte araç kullanan işitme engellilerin sayısını arttırmak ve daha fazla işitme engelliye hayata bağlamak için İl Emniyet Müdürlüklerine bağlı Trafik Tescil ve Denetleme Şube Müdürlükleri 2016-2017 eğitim öğretim yılı içerisinde işitme engellilere işaret dili ile trafik eğitimlerine başlamıştır (Harmancı, 2016). İşitme engelliler trafikte araç kullanırken ambulans, polis ve itfaiye gibi geçiş önceliği olan araçların sirenleri ve uyarı sinyallerini duymadıkları için araçlara yol verme konusunda geç kalabilmektedirler. Özellikle ambulans için bir dakikanın dahi büyük bir önemi vardır. Trafikte araç kullanan işitme engelliler için ambulans, itfaiye, polis gibi araçların siren seslerinin diğer seslerden ayırt edilip algılanması ve hangi yönden geldiğinin tespit edilmesi önemlidir.

Ses kulağın duyabileceği basit titreşimlerdir. İnsan kulağını etkileyerek işitme duyusu oluşturan hava molekülleri titreşimleri, titreşimlerin sebep olduğu küçük hava basınç değişimleri veya bu fiziksel olayın sebep olduğu işitsel izlenim gibi de tanımlanabilir (Aydın, 2005).

Ses tanıma bir akustik sinyali bir karakter setine dönüştüren bir işlemdir (Aydın, 2005). Dışarıdan alınan ses sinyalinin bilgisayar ortamında analog işaretten sayısal işarete dönüştürülerek yani; sayısal verilere dönüştürülerek gerekli programlama ve yazılım teknikleri sayesinde önceden bilinen bir ses ile eşleştirilmesi süreci tanımayı ifade eder. 1950'li yıllardan beri ses tanıma teknolojisi üzerinde çalışılmaktadır. Gün geçtikçe yetkinliği ve doğruluğu veri setinin iyileştirilmesine bağlı olarak artmaktadır. Bir ses tanımının yeterince başarılı olması sayısallaştırılan sesten alınan örneklerin o sesi ne kadar iyi temsil ettiği, alınan örneklerle oluşturulan veri setinin ne kadar iyi olduğuna bağlıdır.

Bu çalışmada ses sinyali sayısal verilere dönüştürülerek verinin içindeki, veriyi en iyi temsil eden ve en anlamlı nitelikler seçilip gereksiz değerlerden arındırılmış veri seti ortaya konulmuştur. Veri seti Destek Vektör Makineleri (DVM) ve K En Yakın Komşuluk (KNN) yöntemi ile sınıflandırılmıştır. Daha önceden veri setinde bulunan

seslerden herhangi biri sisteme verildiğinde sesin trafikte geiş önceliđi bulunan araçlardan birinin uyarıcı sesi olup olmadığı tespit edilmiştir. Ses tespiti yapıldıktan sonra sesin uyarıcı bir ses olduđu ve ses yönü bilgisi verilmiştir.

1.1. Tezin Amacı ve Önemi

Bu çalışmada, işitme engelli bireylerin trafikte rahat araç kullanmalarına katkı sağlamak amacıyla trafikte geiş önceliđi bulunan ambulans, polis, itfaiye gibi araçların siren ve uyarı seslerinin, tanınması ve yönünün belirlenmesine çalışılmıştır.

Temelde ses tanıma ve sınıflandırma içeren bu çalışma işitme engellilerin trafikte daha rahat araç kullanmalarını sağlayacak düzeneklere bir temel oluşturmaktadır. Hem bilimsel açıdan hem de sosyal sorumluluk açısından önemli bir çalışma olma özelliğindedir. Kendinden sonraki çalışmalara örnek oluşturması bilimsel açıdan daha ileri sistemlerin zamanla ortaya konulmasına fayda sağlayacaktır. Aynı zamanda toplum içerisinde işitme engellilerin trafikte yaşadıkları sorunla ilgili farkındalık yaratacaktır. Bu sistem araçlara entegre edilebildiđi takdirde trafikte araç kullanan işitme engellilerin özgüvenini artırıcı yönde etki ederek araç kullanan işitme engelli sayısının da artmasını sağlayacaktır.

2. KAYNAK BİLDİRİŞLERİ

Ses tanıma ve ses işleme işlemleri son zamanlarda birçok akademisyenin çalışma konuları arasında yer almıştır. Özellikle akıllı ev sistemleri ve araç kontrol sistemleri gibi sistemlerde sıkça kullanılmıştır. Araştırmacılar özellikle konuşmacı tanıma sistemleri üzerine çalışmışlardır. Sesin belirli bir kişiye ait olup olmadığının tespitini yapmaya çalışmışlardır. Yapılan kaynak taramalarında araştırmacıların genellikle ses sinyalinin işleme için öznitelik çıkarma (Feature Extraction) ve boyut azaltma (Dimension Reduction) yöntemlerini kullandıkları görülmüştür. Kimi araştırmacılar sadece öznitelik çıkarma algoritmalarını kullanırken kimi araştırmacılar öznitelik çıkarmanın yanı sıra boyut azaltma da kullanmışlardır.

İnal (2001), çalışmasında Yapay Sinir Ağları (YSA) algoritmalarını kullanarak metin bağımlı ve metin bağımsız konuşmacı tanıma sisteminin gerçekleştirilmesi üzerine çalışmıştır. Konuşmacı tanıma ve ses tespit sistemlerinin olmazsa olmazı olan nitelik çıkarma algoritmalarını kullanarak veriyi gereksiz niteliklerden ayırarak YSA algoritmalarıyla tanıma işleminin gerçekleştirilmesini sağlamıştır.

Campbell ve ark. (2002), çalışmalarında öznitelik çıkarma yapıp ses sinyalinin vektörlere dönüştürdükten sonra sınıflandırma yapmışlardır. Saklı Markov Modelleri (SMM) ve diğer tekniklerle beraber uygulanabilen polinomal bir konuşmacı tanıma yöntemi önermişlerdir.

Ertaş ve Hanilçi (2007), bildirimlerinde metinden bağımsız konuşmacı tanıma sistemi için yeni bir sınıflandırıcı önermişlerdir. Çalışmalarında öznitelik çıkarma prensibine dayanan Vektör Nicemleme (VN) algoritmasıyla, yine öznitelik çıkarımından faydalanan fakat sonrasında farklı işlemlere tabi tutulan sınıfsal temel olmayan bileşen analizi algoritması karşılaştırılmıştır.

Hanilçi (2007), tez çalışmasında metinden bağımsız konuşmacı belirleme konusunda sıkça kullanılan yöntemlerden SMM ve VN algoritmalarını incelemiştir. Çıkarılan özellik vektörlerinin en ideal boyutunu tespit edebilmeyi amaçlamıştır. Özellik çıkarma yöntemlerini ve SMM algoritmasını irdeleyerek metin bağımsız bir konuşmacı sistemi ortaya koymuştur.

Başaran (2007), çalışmasında ses işaretlerinin Mel Frekansı Kepstrum Katsayılarını (MFKK) çıkararak özellik vektörleri kümesi oluşturduktan sonra VN yöntemiyle veri boyutunu azaltma işlemi gerçekleştirmiş geriye yayılım algoritması ve YSA ile konuşmacı tespiti yapmaya çalışmıştır.

Senoussaoui ve ark. (2010), çalışmalarında mikrofon ve telefon konuşmasında konuşmacı tanıma için Ortak Faktör Analizi'ne (OFA) dayanan, adına i-vektör dedikleri bir nitelik çıkarma yöntemi önermişlerdir. Sınıflandırma yapmak için de kosinüs mesafelerine dayanan DVM ve Kosinüs Mesafe Skorlaması (KMS) sınıflandırıcılarını kullanmışlardır.

Muda ve ark. (2010), çalışmalarında ses sinyallerinin MFKK ile öznelik çıkarma yaparak nitelik vektörlerini oluşturmuşlardır. Daha sonra Dinamik Zaman Atlama (DZA) olarak bilinen özellik eşleştirme yöntemi ile tanıma işlemini gerçekleştirmişlerdir.

Bala ve ark. (2010), çalışmalarında konuşma sinyalinden değerli bilgileri almak için yani ses sinyalinin özelliklerini çıkarmak için MFKK katsayıları yaklaşımını kullanmışlardır. Bu nitelik çıkarma yöntemiyle ses sinyalinin özellik vektörlerini çıkarmışlardır. Ardından DZA tekniğini nitelikleri eşleştirmek için kullanmışlardır.

Caner ve Üstün (2011), YSA kullanarak Türkçe sesli harflerden kimlik tanıma uygulaması yapmışlardır. Çalışmalarında ses sinyalini alıp belli özellikleri çıkararak veriyi anlamlı hale getirdikten, yani sesi en iyi temsil eden nitelikler çıkarıldıktan sonra karşılaştırma işlemi yaparak konuşmacı tanıma işlemini gerçekleştirmişlerdir.

Nitelik seçme yöntemleri sınıflandırma başarısını belirlemede önemli bir rol oynamaktadır. Nitelik seçme ve nitelik çıkarma konusunda oldukça fazla çalışma bulunmaktadır. Bunlardan bazılarına aşağıda yer verilmiştir.

Ünsalan ve Erçil (1998), çalışmasında Entropi Ölçütü, şekil benzerliği, Fisher Skor ve Temel Bileşen Analizi (TBA) yöntemlerini nitelik seçmek için kullanmışlardır. Nitelik seçme yöntemlerinin başarılarını karşılaştırarak yeni bir nitelik seçme yöntemi önermişlerdir. Ayrıca tüm nitelik seçme yöntemlerinin başarılarını hesaplamak için yeni bir yöntem geliştirmişlerdir.

Vogt ve ark. (2008), çalışmalarında duyguların sestten çevrimiçi olarak tanınması üzerine çalışmışlardır. Çevrimiçi kullanıcının duygu durumunu sesli bilgilerden çıkarabilmek için; önce ses işaretinin özellik vektörlerini çıkarıp bu çıkarılan veri

içerisindeki, veriyi en iyi temsil eden verileri nitelik seçerek ideal veri setini oluşturduktan sonra sınıflandırma işlemini gerçekleştirmişlerdir.

Eskidere (2012), Parkinson hastalığının teşhisi için biyomedikal ses ölçümlerinden oluşan veri setinde altı farklı nitelik seçme yöntemini deneyerek karşılaştırmıştır. Bu karşılaştırma sonucunda Parkinson hasta veri seti için DVM-YÖE nitelik seçme yönteminin % 95.13 doğru sınıflandırma oranı ile en iyi tanıma sonucunu veren nitelik seçme metodu olduğunu tespit etmiştir.

Kaynar ve ark. (2018), çalışmalarında saldırı tespiti için birçok nitelik seçme algoritmasını farklı sınıflandırma algoritmalarıyla beraber kullanarak boyutu azaltılmamış veriyle nitelik seçme yöntemleri ile azaltılmış verinin başarı durumunu karşılaştırmışlardır.

Karacalarlı (2018), çalışmasında DVM sınıflandırma metodu kullanan saldırı tespit sistemlerinin performansının nitelik seçme ile artırılabilmesi üzerine çalışmıştır. Çalışmada DVM ile yapılan sınıflandırma performansının, Fisher Score nitelik seçim yöntemiyle artırılabilirdiğini tespit etmiştir.

Sezer (2018), çalışmasında bankacılık müşteri verisi üzerinde sınıflandırma yapmak için farklı nitelik seçme yöntemlerini irdelemiştir. Sınıflandırma sonuçlarını karşılaştırarak farklı nitelik seçme yöntemlerinin performanslarını gözlemlemiştir.

Yakut (2018), çalışmasında otomatik aritmili kalp atımlarını sınıflandıran bir yöntem önermiştir. EKG işaretindeki aritmilerin sınıflandırılması için 4 farklı nitelik çıkarma yöntemi deneyerek nitelikleri çıkardıktan sonra nitelik seçimi yaparak en anlamlı alt kümeleri oluşturmuştur. Bu alt kümeler kullanılarak önerilen sınıflandırma yöntemi ve bilinen sınıflandırma yöntemleriyle sınıflandırılarak karşılaştırma yapılmıştır. Nitelik seçme yöntemiyle veriyi en çok temsil eden verileri seçerek daha yüksek doğrulukta sınıflandırma yapılmasını sağlamıştır.

Elgün (2019), çalışmasında biyoinformatik veri sınıflandırma problemleri için nitelik seçme yöntemlerini irdeleyerek nitelik seçimi sağlayan yeni bir biyoinformatik yaklaşım önermiştir.

Altun ve Polat (2008), çalışmalarında ses sinyali üzerinde 4 farklı sınıflandırma yöntemi denemişlerdir. DVM, Çok Katmanlı Algılayıcı (ÇKA), KNN Algoritması ve Radyal Tabanlı Fonksiyon Ağları (RTFA) yöntemlerini karşılaştırmışlardır. Sınıflandırma problemleri için “en uygun” niteliklerin belirlenmesinin, “en uygun”

sınıflandırma yönteminin belirlenmesinden daha önemli olduğunu savunmuşlardır ve en iyi niteliklerin belirlenmesi için Prosodik Öznitelikler, Alt-Band Enerji Öznitelikleri, MFKK, Doğrusal Tahmini Kodlama (DTK) olmak üzere 4 farklı nitelik grubuna ait nitelik vektörleri oluşturmuşlardır.

Campbell ve ark. (2006), çalışmalarında DVM'yi konuşmacı ve dil tanıma için uygulamışlardır. Bu çalışmada vektörlerinin dizilerini karşılaştıran ve benzerlik ölçüsü üreten bir çekirdeğin kullanılması yaklaşımı vardır. Bu çalışma DVM'nin model sınıflandırma için güçlü bir teknik olduğunu kanıtlamışlardır.

İncelenen çalışmalarda insan sesi, biyomedikal sesler gibi seslerin tespiti yapılırken, bu tez çalışmasında trafikte geçiş önceliği olan araçların uyarı seslerinin tespiti yapılmaya çalışılmıştır. Ambulans, polis, itfaiye gibi geçiş önceliği bulunan araçların siren seslerinin tanınması sağlanmaya çalışılmıştır.

3. MATERYAL VE YÖNTEM

Bir ses tanıma sisteminin sesi tanıyabilmesi için ses sinyalinin doğru bir şekilde ifade edilmiş olması gerekir. Yani ses içerisindeki sadece o sesi tanımlayan unsurların belirli sinyal işleme teknikleriyle ortaya konulmuş olması gerekir (Dede ve Sazlı, 2010). Tanınmaya müsait hale gelen veri, ses tanıma sistemi tarafından tanınabilir. İşitme engelliler için uyarı seslerinin tanınmasını sağlayan sistemde, alınan seslerin tanınabilmesi için de sesin bazı işlemlerden geçmesi gerekmektedir. Aşağıda ham verinin alınmasından sesin tanınmasına kadar olan sistem yapısı anlatılmıştır:

3.1. Ham Veri Toplama

Kişisel bilgisayar yardımıyla trafikte geçiş önceliği bulunan araçların uyarıcı sesleri ve bunların dışında kalan trafik ortamında olabilecek gürültü, müzik, araç kornası gibi diğer sesler kaydedilir.

Veri seti 47 olumlu ve 47 olumsuz sestten oluşur. Olumlu sesler ambulans, polis ve itfaiye siren seslerinden oluşurken, olumsuz sesler sokak gürültüsü, korna sesi, müzik sesi gibi trafikte olabilecek siren sesleri dışındaki seslerden oluşmaktadır. Her bir ses 2 saniye uzunluğundadır.

Bilgisayarda “.wav” formatında bulunan sesler kodlama ortamından çağırılarak “.wav” formatındaki giriş sayısal değerlere sahip bir matris haline dönüşür. Burada dinleyebildiğimiz “.wav” formatındaki ses artık sayısal değerlerle ifade edilir.

3.2. Öznitelik Çıkarma

Sayısallaştırılmış ses verisi öznitelik çıkarma işlemine tabi tutulur.

Öznitelik çıkarma ses işaretinin o sese özgü parametrelerin vurgulandığı ses ile ilgili bilgi içermeyen kısımların atıldığı vektörlere dönüştürme işlemidir. Öznitelik çıkarma, matematiksel yüksek boyutlu vektörlerin daha düşük boyutlu vektörlere indirgenmesi olarak da tanımlanabilir (Hanilçi, 2013). Öznitelik çıkarma sınıflandırma

performansını etkilediği için tanıma sisteminin önemli adımlarından biridir (Uğuz ve Arslan, 2010).

3.2.1. Tanımlayıcı istatistik

Sayılaştırılmış ses sinyalinde o sese özgü niteliklerin tutulup sesi yansıtmayan niteliklerin atılarak, ses sinyalinin nitelik vektörünün çıkarılması için temel tanımlayıcı istatistiksel yöntemler kullanılabilir. Ses belli uzunlukta parçalara ayrılarak istatistiksel değerlerinin çıkarılmasıyla icra edilir. Parçalara ayrılan ses örneklerinin her kısımdaki veri setinin ayrı ayrı ortalama ve standart sapma değerleri hesaplanır. Daha sonra her kısımdaki veriyi temsilen sadece ortalama ve standart sapma değerleri alınıp tüm ortalama ve standart sapma değerleriyle yeni bir matris elde edilir. Bu şekilde nitelik vektörleri çıkarılmış olur.

3.2.2. Doğrusal tahmini kodlama (DTK) yaklaşımıyla öznelik çıkarma

DTK, ses sinyalinin karakteristiğinin iyi bir şekilde tahmin edilmesini sağlayan bir model ortaya koyar. Nitelik çıkarma işlemlerinin adımları Şekil 3.1’de gösterilmiştir. Gelen ses sinyali ilk olarak çerçeve bloklama aşamasından geçirilerek çerçevelere bölünür. Sinyalin başındaki ve sonundaki süresiz bölümleri en aza indirmek için her çerçeve pencerelenir. Pencerelenen her sinyal otokorelasyon analizine tabi tutulur. Daha sonra her bir çerçeveye ait otokorelasyondan DTK parametre kümesi hesaplanır. Daha sonra kepsral analiz yapılarak DTK katsayıları kepsral katsayılara dönüştürülür. Kepsral ve delta kepsrum katsayıları kullanılarak istenilen M boyutlu gözlem vektörü elde edilir.



Şekil 3.1. Nitelik çıkama adımları (Uğuz ve Arslan, 2010).

Çerçevelemede ses sinyali üzerinde kısa zamanlı spektral analiz yapabilmek için sürekli ses sinyali, N adet örnekten oluşan çerçevelere bölünür. İlk çerçeve N örnekten

oluşurken ikinci çerçeve ilk çerçeveden K örnek sonra başlar ve ilk çerçevenin $N - K$ örnek kadar üzerine biner. Aynı şekilde üçüncü çerçeve ilk çerçeveden $2K$ örnek, ikinci çerçeveden K örnek sonra başlar ve ilk çerçevenin $N - 2K$ örnek kadar üstüne biner. Bu işlem tüm ses sinyali boyunca yapılır (Başaran, 2007).

Çerçevelemeden sonraki işlem pencereleme olup, her çerçeve pencerelenerek, sinyalin başındaki ve sonundaki süresiz bölümler minimize edilir. Buradaki amaç, pencereyi kullanarak çerçevelerin başı ve sonundaki bilgi içermeyen bölümleri kırmak, ve buna bağlı olarak spektral bozulmayı engellemektir (Başaran, 2007). Bu uygulamada Hamming pencerelemesi kullanılmıştır. Hamming pencerelemesi merkez noktalarda bilgileri gösterirken, uç noktalarda bozulmalar olur. Pencereleme yönteminin bu etkisi, pencerelerin üst üste binmesi ile aşılr (Uğuz ve Arslan, 2010).

Pencerelenmiş sinyalin her bir çerçevesine otokorelasyon analizi uygulanır. Otokorelasyon analizinde sıfırcı otokorelasyon ilgili çerçevenin enerjisini ifade eder. Bir çerçevenin enerjisi ses tanıma işlemleri için önemli bir değişkendir (Uğuz ve Arslan, 2010).

DTK analizi aşamasında her bir çerçeveye ait otokorelasyondan DTK parametre kümesi hesaplanır. DTK analizi, verilen ses sinyalinden, süzgeç katsayılarının belirlenmesi işlemidir. Katsayılar belirlenirken gözlenen sinyal ile asıl sinyal arasındaki farkın minimum olması sağlanmaya çalışılır (Şentürk, 2015).

Kepstral analiz için ise, DTK analizinden sonra oluşan DTK katsayıları kepsrum katsayılarına dönüştürülür. DTK katsayıları modelleme için yeterli olmadığından daha güçlü bir nitelik vektörü oluşturulabilmesi için kepsrum analiz uygulanarak DTK katsayıları kepsrum katsayılarına dönüştürülür.

3.2.3. Hızlı fourier dönüşümü (HFD) ile öznelik çıkarma

Ayrık Fourier dönüşümünün (AFD) hızlı bir şekilde hesaplanmasına imkân veren yöntemler Hızlı Fourier Dönüşümü (HFD) olarak isimlendirilir. AFD'deki faz faktörünü simetri ve periyodiklik özellikleri kullanılarak AFD'nin daha verimli hesaplanabilmesi mümkün olmaktadır. HFD, ayrık Fourier hesabı için faz faktörünün simetrik ve periyodiklik özelliğinden faydalanarak hızlı bir hesaplama sağlar (Ertürk, 2009).

3.3. Boyut Azaltma

Sisteme verilen ses sinyali sayısallaştırılıp gereksiz veriler atılarak sesin önemli özelliklerini barındıran nitelik vektörü oluşturulduktan sonra sınıflandırma başarısını artırmak için veri boyutu azaltılır. Veri boyutunun azaltılması veri setinin kalitesini artırırken sınıflandırma başarısını da yükseltmektedir. Bu boyut azaltma işleminin nitelik çıkarımı ve nitelik seçimi olmak üzere iki türü vardır.

3.3.1. Nitelik seçimi

Öznitelik çıkarma işleminden sonra sınıflandırma öncesi yüksek doğruluk sağlamak için nitelik seçme işlemi uygulanır.

Nitelik seçimi, ses işaretinin değer vektöründeki en anlamlı ses verisini en iyi ifade eden, sesin özelliğini en çok taşıyan değerlerin seçilmesidir. Nitelik seçme sınıflandırma performansını en çok etkileyen faktörlerden biridir (Kaynar, 2018). Nitelik seçim yöntemleri bazı niteliklerin elenerek kalanların hiç değiştirilmeden kullanıldığı yöntemlerdir (Kaynar, 2018). Başka bir deyişle nitelik seçme doğruluğunu düşürmeden veri boyutunu azaltma yöntemidir (Ertuğrul ve Tağluk, 2017).

Yedi farklı nitelik seçme yöntemi ele alınmıştır.

Aşırı Öğrenme Makinesi ve Değişim Katsayısına Dayalı Hızlı Özellik Seçimi Yaklaşımı, Ertuğrul ve Tağluk'un (2017), TUBİTAK Türkiye Elektrik Mühendisliği ve Bilgisayar Bilimleri Dergisinde önermiş oldukları bir nitelik seçim algoritmasıdır. Değişim katsayısı (DK), verilerin standart sapma oranının ortalama değerine oranını gösterir. Bu yöntemde veriyi en iyi temsil eden nitelik her bir niteliğin katsayıya göre sıralanmasıyla tanımlanır. Bu katsayı Aşırı Öğrenme Makinesi (AÖM)'nin DK'ya bölünmesiyle elde edilir. Küçük bir DK değeri, verinin veri setindeki parçalar arasında az bir farklılığın olduğunu gösterir. Yani en düşük DK değerine sahip nitelik en iyi niteliktir. Buna bağlı olarak eğitilmiş AÖM'den belirlenen veri setlerinden ve katsayılarından hesaplanan DK değerleri bu yöntemde özellik sıraları olarak kullanılır.

Relief yöntemi, Kira ve Rendell (1992) tarafından önerilen Relief yöntemi, niteliklerin değerini aralarındaki ilişkileri ortaya çıkartmaya çalışarak bulan bir nitelik seçme algoritmasıdır. Relief yöntemi, iki sınıfı olan veri setleri için başarılı bir nitelik

çıkarma yöntemiyle ikiden fazla sınıfın olduğu veri setlerinde kullanılamamaktadır. Bu yöntemin mantığı komşuluk algoritmalarının mantığına benzemektedir. Niteliğin ait olduğu ve ait olmadığı sınıflardaki niteliklere olan uzaklıklarının ağırlıklandırılmasıyla gerçekleştirilir.

Relief algoritması 3 önemli adımdan oluşur: (Budak, 2018).

1. Aynı sınıfa sahip en yakın örnekteki ilgili nitelik değeri ve farklı sınıfa sahip en yakın örnekteki ilgili nitelik değerinin belirlenmesi,

2. İlgili niteliğin ağırlığının hesaplanması,

3. Niteliklerin ağırlıklarına göre sıralanması ve belirli bir eşik değeri veren üstteki k adet niteliğin seçilmesi

Yukarıda anlatılan adımlar uygulanarak nitelik seçimi yapılmış olur.

Fisher Skor yöntemi, her bir sınıf için niteliklere ait ortalama ve standart sapma değerlerini kullanarak bir ilişki skoru verir (Budak, 2018). Bu skor iki sınıfın aritmetik ortalamalarının farkının iki sınıfın standart sapmaları arasındaki farka bölünmesiyle elde edilir. Bu yöntem iki sınıfı birbirinden ayıracak nitelikler bulmaya çalışır. Bu yöntemde nitelik seçme işlemi, niteliklerin hesaplanan skorlara göre büyükten küçüğe sıralanması ve sonrasında en üst sıradan başlanarak istenen sayıda niteliğin seçilmesi şeklinde olmaktadır (Budak, 2018).

Sonsuz Gizli Özellik Seçimi (SGÖS) yöntemi, Roffo ve ark. (2017) tarafından önerilen bir nitelik seçme yöntemidir. Bu yöntem, birleşim sorununu aşarak tüm olası nitelik alt kümelerini göz önüne alarak sıralama adımını gerçekleştiren olasılıklı bir gizli nitelik seçimi yaklaşımıdır. SGÖS güçlü bir olasılıksal gizli graf tabanlı nitelik seçim algoritmasıdır. Nitelik alt kümelerini birleştirerek bağlantıları yol olarak belirler. Her yolun maliyeti ortak düğüm tarafından verilir. Niteliğe ait tüm düğümlerin olasılıkları hesaplanır. Bu şekilde her bir niteliğin, diğerlerine göre alaka düzeyini değerlendirir (Roffo ve ark., 2017).

İçbükey Minimizasyon ile Nitelik Seçimi (İMNS) yöntemi, Bradley ve Mangasarian (1998) tarafından 1998 yılında önerilen bir nitelik seçme yöntemidir. İçbükey küçültme yaklaşımında, yanlış sınıflanan noktaların ağırlıklı toplamları ile kümeleri bağlayan ve aralarındaki ayırma düzlemini ortada belirleyen iki paralel düzlemin ağırlıklı toplamının en aza indirilmesiyle bir ayırma düzlemi oluşturulur. Ayrıca, düzlemi belirlemek için kullanılan boşluğun boyut sayısı da en aza indirilir.

Başka bir deyişle; iki sınıflı bir sınıflandırma problemi için veri setindeki değerlerden seçilecek nitelikleri belirlemek için kullanılan bu yöntem ağırlıkların minimizasyonuna dayanır (Bradley ve Mangasarian 1998).

Yinelemeli Özellik Eleme (YÖE) yöntemi, Guyon ve ark. (2002) tarafından önerilen bu yöntem bir tür geriye doğru nitelik seçme yöntemidir. YÖE yöntemi sınıflandırma performansını artıran nitelik alt kümesini bulmak için, tüm özellikleri bir amaç fonksiyonuna bağlı olarak derecelendirir ve daha sonra en düşük dereceye sahip niteliği nitelik kümesinden çıkarır. Bu işlem en yüksek sınıflandırma başarısı elde edilene kadar devam eder (Budak, 2018).

En Küçük Mutlak Çekme ve Seçme Operatörü (EMÇSO) yöntemi, model parametrelerinin mutlak değerlerinin toplamını sabit bir değerden daha küçük tutarken tahmin hatasını en aza indirir. Bu yöntemde toplam durum değiştirilmeden, regresyon değişkenlerinin katsayılarını cezalandırırken katsayıları sıfır olanlar en alakasız nitelikler olarak belirlenir. Katsayısı sıfır olmayanlar modelin bir parçası olarak yani anlamlı nitelikler olarak seçilirken katsayısı sıfır olanlar veri setinden atılır (Liu ve Motoda, 2007).

3.3.2. Nitelik çıkarımı

Bu aşamada nitelik çıkarımı için Temel Bileşen Analizi (TBA) yöntemi seçilmiştir. TBA veri boyutunu azaltmak için sıklıkla kullanılan denetimsiz lineer dönüşüm tekniğidir. TBA veri dağılımındaki sapmanın en iyi şekilde korunmasını sağlayacak şekilde veri setini yeni bir veri uzayına taşır (Ünsalan ve Erçil, 1998). Yeni oluşturulan veri setinde en iyi özellikler en başa alınır.

TBA ile çıkarılıp en iyi özelliklerin en başa alındığı veri setinden baştan başlanarak belli sayıda özellik kullanılır. Bu özellikler son durumda boyutu azaltılmış olan veri setini oluşturur. Bu özellikler ile artık eğitim ve test setleri oluşturulmaya hazırdır.

3.4. Sınıflandırma

Boyut azaltma işlemi yapıldıktan sonra eğitim ve test setleri ayarlandıktan sonra veri seti sınıflandırma işlemine tabi tutulur.


Sınıflandırma, veri seti üzerinde tanımlı olan çeşitli sınıflar arasında veriyi dağıtmak olarak tanımlanabilir. Sınıflandırma algoritmaları, verilen eğitim kümesinden dağılım şeklini öğrenip daha sonra sınıfının belli olmadığı test verileri geldiğinde doğru şekilde sınıflandırmaya çalışan algoritmalarıdır. Sınıflandırma işleminde ilk olarak eğitim kümesi kullanılarak bir model oluşturulur. Bu adımda giriş değişkenlerine ait veriler ve hedef değişkeni temsil eden sınıf değerleri sınıflandırma algoritmasına giriş olarak verilir. Sınıflandırma algoritması bilinen girdi ve çıktı değerlerini kullanarak bir model oluşturur. Sonraki adımda ise, eğitim verileri kullanılarak geliştirilen model yeni bir veri kümesi üzerinde test edilir. Ama bu aşamada modele giriş olarak hedef değişkene ait sınıf bilgisi verilmez. Bunun yerine modelin test kümesindeki değişkenlerin hangi sınıfa ait olduğunu doğru olarak tahmin etmesi beklenir (Seyrek ve Ata, 2010).

3.4.1. KNN algoritması

KNN algoritması veri setindeki en yakın eğitim örneklerine dayanarak nesnelere sınıflandıran, en basit örüntü tanıma metotlarından birisidir (Karakoyun ve Hacıbeyoğlu, 2014). Tüm mevcut durumlara göre bir benzerlik ölçüsüne (mesafe fonksiyonları) göre yeni durumları sınıflandıran basit bir algoritmadır. Sınıflandırılacak olan verinin komşularıyla arasındaki uzaklığa bakarak ona göre sınıflandırma işlemini gerçekleştirir (Pilavcılar, 2007). KNN sınıflandırmasında yaygın olarak kullanılan mesafe fonksiyonlarından üçü Minkowsky, Euclidean ve Manhattan yöntemleridir (Taşçı ve Onan,2016). Bu yöntemlerden biriyle mesafe hesabı yapıldıktan sonra belirlenen bir k değerine göre en yakın k tane komşuya göre dâhil edileceği sınıf belirlenir. Test edilecek örnek, eğitim kümesindeki her bir örnek ile tek tek karşılaştırılır. Test edilecek örneğin sınıfını belirlemek için eğitim kümesindeki o örneğe en yakın k tane komşuya bakılır en yakın k tane komşudan hangi sınıfa ait olan daha fazla örnek varsa sınıflandırılacak veri de o sınıfa dâhil edilir (Karakoyun ve Hacıbeyoğlu, 2014).

3.4.2. DVM ile sınıflandırma

Cortes ve Vapnik (1995) tarafından önerilen DVM yapısal risk minimizasyonu prensibini kullanmaktadır. DVM; doğru, düzlem ya da hiper düzlem yardımı ile verileri iki sınıfa ayıran bir makine öğrenmesi yöntemidir (Kaynar ve ark., 2018). DVM, sınıflandırma veya regresyon problemleri için kullanılabilen denetimli bir makine öğrenmesi algoritmasıdır. DVM özellikle son yıllarda çok farklı görevler için kullanılan sınıflandırıcılardan biridir (Eskidere, 2012). DVM, sınıflandırma yapmak için bir düzlemde bulunan iki grup arasında çizilen bir sınır ile iki grubu ayırmaya çalışır. Bu sınırın (karar sınırı) çizileceği yerin iki grubun da üyelerine en uzak olan yer olması gerekmektedir. İşte DVM bu sınırın nasıl çizileceğini belirler. Bu işlemin yapılması için iki gruba da yakın ve birbirine paralel iki sınır çizgisi çizilir (negatif ve pozitif düzlem) ve bu sınır çizgileri birbirine yaklaştırılarak ortak sınır çizgisi üretilir. Başka bir deyişle, DVM iki sınıfı ayıran en iyi çizgiyi bulmaya çalışır. Bu yöntemde, iki sınıf arasındaki birbirine en yakın örneklerin uzaklıklarının maksimumlaştırıldığı yüksek bir düzlem bulunmaya çalışılır. Bu yöntem sıklıkla doğrusal olarak ayrışabilen veriler için kullanılabilirdiği gibi, çekirdek fonksiyonları yardımı ile verileri doğrusal olarak ayrıştırılabilir duruma getirebildiği için doğrusal olarak ayrışamayan veriler için de kullanılabilir (Kaynar ve ark., 2018). Yani DVM hem doğrusal hem de doğrusal olmayan verileri sınıflandırabilir. Ancak daha çok doğrusal verileri sınıflandırmak için kullanılır. Bu anlatılan destek vektörleri ve oluşturulan düzlemler Şekil 3.2’de görselleştirilmiştir.



Şekil 3.2. Destek vektörleri ve düzlemler (Anonim, 2018).

Sınıflandırıcının çalışma prensibi bir örnek verilerek anlatılacak olursa: veriler tespit edilecek sınıf etiketi 1 ve diğer sınıftaki tüm veriler -1 olacak şekilde etiketlenerek sınıflandırılır. Bu işlem her sınıf için tüm modeller üzerinde ayrı ayrı tekrarlanır. Son olarak modellerden elde edilen sonuçlar birleştirilerek gerçek sınıf bilgisi ortaya konulmuş olur.

3.4.3. Sınıflandırma başarısının tespiti

Sınıflandırma başarısı değerlendirilirken doğruluk, duyarlılık ve özgüllük oranlarına bakılır. Sınıflandırma yönteminin başarısı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atılan örnek sayısı miktarıyla alakalıdır (Coşkun ve Baykal, 2011).

Sınıflandırma ile ulaşılan sonuçların başarı bilgileri karışıklık matrisi ile ifade edilebilir. Karışıklık matrisinde satırlar test kümesindeki örneklere ait gerçek sayıları, sütunlar ise sınıflandırmanın tahminlerini ifade eder (Coşkun ve Baykal, 2011).

		Öngörülen Sınıf	
		Sınıf=1	Sınıf=0
Doğru Sınıf	Sınıf=1	a	b
	Sınıf=0	c	d

a: TP (True Pozitif) c: FP (False Pozitif)
b: FN (False Negatif) d: TN (True Negatif)

Şekil 3.3. Karışıklık Matrisi (Coşkun ve Baykal, 2011).

Doğruluk, doğru sınıflandırılmış örnek sayısının, toplam örnek sayısına oranıdır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

Duyarlılık, doğru sınıflandırılmış pozitif örnek sayısının toplam pozitif örnek sayısına oranıdır.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.2)$$

Özgüllük, gerçek negatif sayısının gerçek negatif ile yanlış pozitif sayılarının toplamına oranıdır.

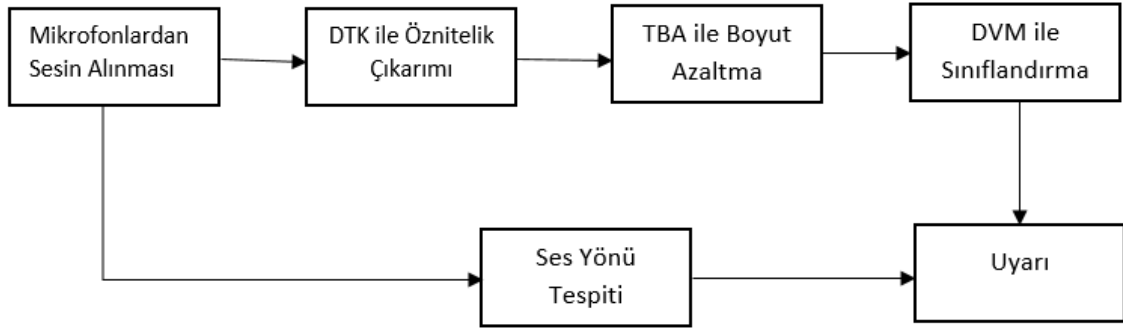
$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (3.3)$$

Bu üç başarı ölçütü değerinin yüksek olması sınıflandırma başarısının yüksek olduğunu gösterir.



4. BULGULAR

İşitme engelliler için ambulans, polis ve itfaiye gibi trafikte geçiş önceliği bulunan araçların siren seslerini tanıyacak sistemi ortaya koyabilmek için birden fazla yol izlenmiştir. Bu sayede en iyi sonucu veren yolu bulmak hedeflenmiştir. Şekil 4.1’de önerilen yöntem şematize edilmiştir.



Şekil 4.1. Sistem modeli.

Şekil 4.1’de gösterilen en iyi sonucu veren nihai sistemde sesin tanınması ve sesin yönünün belirlenmesi olmak üzere iki aşama vardır. Sesin tanınması aşamasında, ilk olarak mikrofondan sesler alınır, DTK ile öznitelik çıkarımına ve ardından TBA ile boyut azaltma işlemine tabi tutulur. TBA ile boyutu azaltılan veri DVM ile sınıflandırılarak ses tanındıktan sonra uyarı verilir. Sistemin ikinci aşaması olan ses yönü tespitinde ise, sesler mikrofonlardan alınır ve sesin yakın olduğu mikrofona göre sesin yönüne karar verilir.

Aşağıda siren seslerinin tanınması için izlenen tüm yollar ve tanıma süreci anlatılmıştır.


4.1. Ham Verinin Toplanması

Bilgisayar ortamında ses kayıtları alınıp, olumlu ve olumsuz ses kategorisine ayrılmıştır. Olumlu sesler ambulans, polis ve itfaiye araçlarının siren sesleridir. Olumsuz sesler ise trafikte karşılaşılabilecek trafik ve sokak gürültüsü, korna sesleri, müzik sesi vb. seslerdir. Burada her bir ses 2 saniyedir. Normalde bir ambulans, polis ve

itfaiyeye ait siren sesinin uzunluđu daha fazladır. Fakat sesin sayısallaştırılmasının, üzerinde işlem yapılmasının ve karşılaştırılmasının daha hızlı ve kolay yapılabilmesi için uzun sesler 2 saniyelik kısımlara ayrılarak kaydedilmiştir. Sonuç olarak 47 olumlu 47 olumsuz olmak üzere toplam 94 ses kaydedilmiştir.


İkişer saniyelik sesler olumlu olumsuz kategorisine göre yerleştirildikten sonra “.wav” formatındaki ses bilgisayar ortamına alınmıştır. “.wav” formatındaki 2 saniyelik her ses bilgisayar ortamına alındığında 88200x2’lik bir matrise dönüşür. Tek kanallı yapılan kayıtlar için bu iki sütun tamamen aynı değerlere sahiptir. Tanıma işlemini gerçekleştirebilmek için sadece bir sütunu alarak işleme tabi tutmak yeterli olduğundan bu matrisin yalnızca bir sütunu alınarak sonraki işlemler gerçekleştirilmiştir. 47 olumlu 47 olumsuz olmak üzere 94 sesin tamamı bu şekilde bilgisayar ortamına alınmıştır. Sesin tanınabilmesi ancak onu ifade eden sayısal değerler incelenerek yapılabilir. Başka bir deyişle sesi bilgisayarın anlayabileceđi, yorumlayabileceđi bir şekilde dönüştürmek gerekir.

Bilgisayar ortamına alınan seslerden örnek bir olumlu sese ait grafik Şekil 4.2’de gösterilmiştir.



Şekil 4.2. Örnek bir olumlu ses sinyali.

Bilgisayar ortamına alınan seslerden örnek bir olumsuz sese ait grafik Şekil 4.3'de gösterilmiştir.




Şekil 4.3. Örnek bir olumsuz ses sinyali.

4.2. Öznitelik Çıkarma

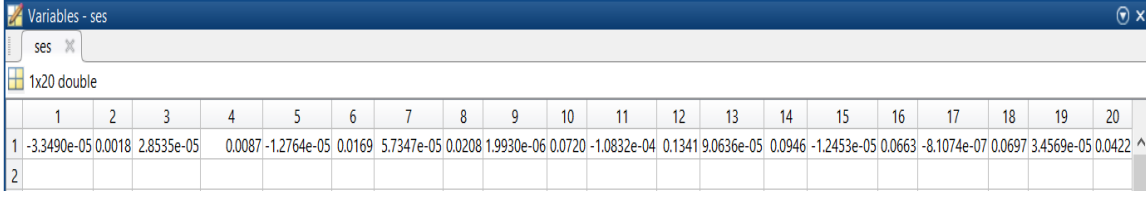
Ses bilgisayar ortamına alındıktan sonra sesin özelliklerini en çok taşıyan nitelikler tespit edilmiştir. Sesin içerisinde bulunan fakat sesin tanınmasını zorlaştıracak sesin özelliklerini yansıtmayan nitelikler atılmaya çalışılmıştır. Yapılan bu işlem öznitelik çıkarma işlemidir. Öznitelik çıkarma işlemi, sonrasında yapılacak sınıflandırma performansını etkileyen bir adımdır. Öznitelik çıkarma için üç farklı yöntem denenmiştir. Bunlardan ilki tanımlayıcı istatistik yöntemi, ikincisi DTK yöntemi, üçüncüsü ise Hızlı Fourier Dönüşümü yöntemidir.

İlk olarak tanımlayıcı istatistik yöntemi uygulanmıştır. Bilgisayar ortamına alınan 2 saniyelik bir ses 88200 değerle ifade edilir. Şekil 4.4'te 2 saniyelik örnek bir sesin grafiği gösterilmiştir.



Şekil 4.4. İki saniyelik bir ses sinyali.

Her bir ses 10 parçaya bölünerek her parçanın standart sapma ve ortalaması hesaplanmıştır. 88200 değerle ifade edilen her ses 10 parçaya bölünerek her 8820 değer için bir standart sapma ve bir ortalama değer hesaplanmıştır. Bu şekilde her bir ses örneği için elde edilen 10'u standart sapma 10'u ortalama olan 20 değer ile yeni bir öznitelik vektörü oluşturulmuştur. Bu şekilde 88200x1'lik matris ile ifade edilen her bir ses 1x20'lik bir vektöre dönüşmüştür. Her bir ses artık 88200 değerle değil 20 değerle ifade edilmiştir. Şekil 4.5'de 88200x1'lik matristen 1x20'lik matrise dönüşen örnek bir ses gösterilmiştir.



	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	-3.3490e-05	0.0018	2.8535e-05	0.0087	-1.2764e-05	0.0169	5.7347e-05	0.0208	1.9930e-06	0.0720	-1.0832e-04	0.1341	9.0636e-05	0.0946	-1.2453e-05	0.0663	-8.1074e-07	0.0697	3.4569e-05	0.0422
2																				

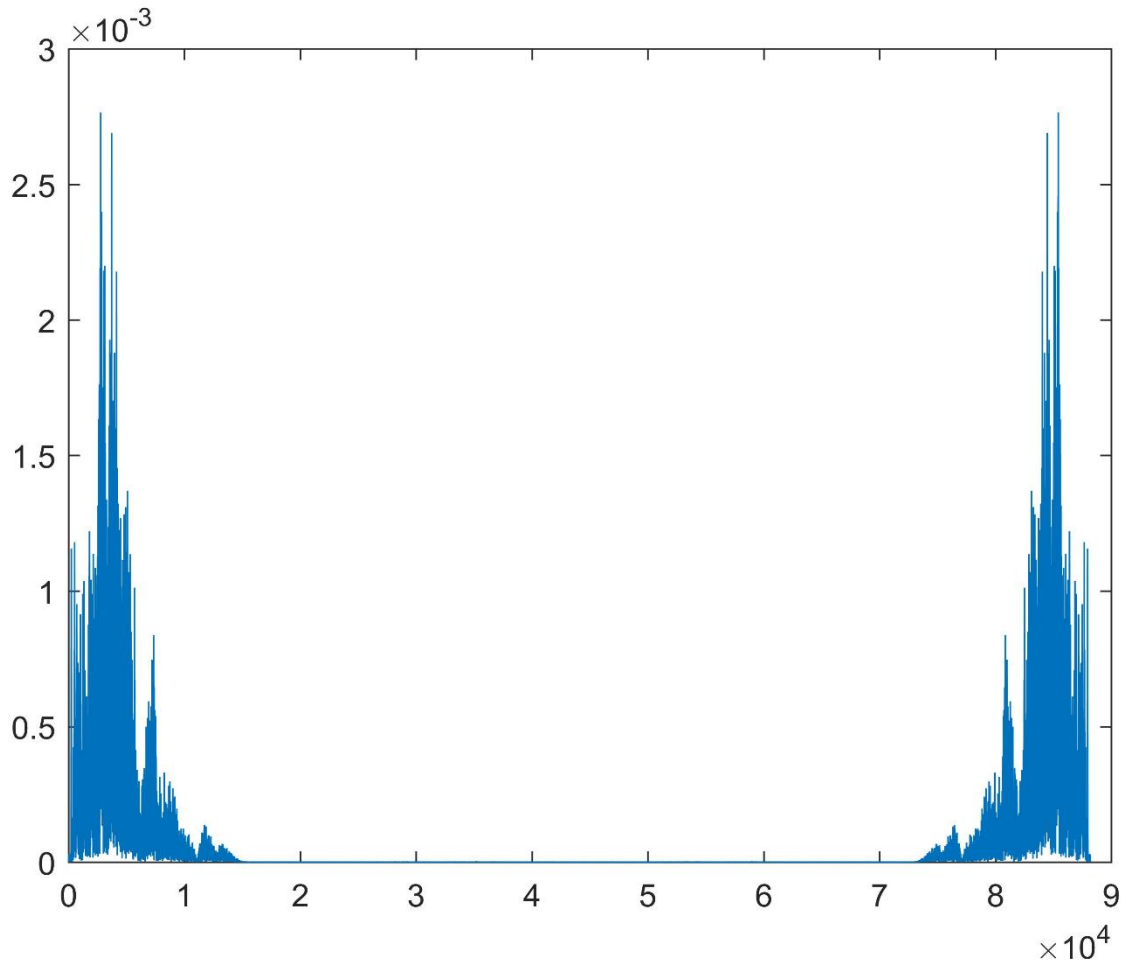
Şekil 4.5. Tanımlayıcı istatistik uygulanmış bir ses sinyali.

Kayıtlı olan 94 sesin tümü için bu işlemler uygulanmıştır. Ardından 94x20'lik bir matrisle ifade edilen nitelik vektörleri elde edilmiştir.

İkinci öznelik çıkarma yöntemi olarak DTK kullanılmıştır. Ses sinyali yapılan kodlama ile sırasıyla Şekil 3.1'deki nitelik çıkarma adımlarına tabi tutulmuştur. Yapılan kodlama ile ses sinyali ilk olarak çerçeve bloklama aşamasından geçirilerek çerçevelere bölünmüştür. Sinyalin başındaki ve sonundaki süreksiz bölümleri en aza indirmek için her çerçeve hamming pancereleme yöntemiyle pencerelenmiştir. Pencerelenen sinyal otokorelasyon analizine tabi tutulmuştur. Daha sonra her bir çerçeveye ait otokorelasyondan DTK parametre kümesi hesaplanmıştır. Daha sonra Kepstral analiz yapılarak DTK katsayıları kepstral katsayılara dönüştürülmüştür. Kepstral ve delta kepstrum katsayıları kullanılarak 10 boyutlu gözlem vektörü elde edilmiştir. Bu işlemler sonucunda 88200x1'lik matris ile ifade edilen bir ses sinyali 10x550'lik bir matrise ve ardından her bir ses 5500 değerle ifade edilebilen tek satırlık 1x5500'lük bir vektöre dönüşmüştür.

Her bir ses için bu işlemler uygulandıktan sonra tüm seslerden oluşan 94x5500'lük nitelik vektörleri elde edilmiştir.

Üçüncü öznelik çıkarma yöntemi olarak HFD kullanılmıştır. Kodlama ortamına alınıp 2 saniyelik 88200 değerle ifade edilen her ses sinyali hızlı Fourier dönüşümüne tabi tutulmuştur. Şekil 4.6'da HFD uygulanmış örnek bir ses sinyali gösterilmiştir.



Şekil 4.6. HFD uygulanmış örnek bir ses sinyali.

HFD'ye tabi tutulan her ses sinyali yine 88200 değerle ifade edilen 88200×1 'lik bir matrise dönüşmüştür. Tüm sesler için bu işlem uygulanmış ve tüm seslerden oluşan 94×88200 'lük bir matris elde edilmiştir. Elde edilen bu matristen ilk 5500 değer değer alınarak 94×5500 'lük bir matris ile ifade edilen yeni veri seti oluşturulmuştur.

Tanımlayıcı istatistik yöntemi DTK ve HFD yöntemlerine göre daha temel basit hesaplama tekniklerine dayanmaktadır. Önce tanımlayıcı istatistik yöntemiyle nitelik çıkarma işlemi yapılmıştır. Ardından önce KNN ile daha sonra DVM ile sınıflandırma yapılmıştır. Yapılan bu sınıflandırmalar sırasında 2 katlı çapraz doğrulama uygulanmıştır. Tanımlayıcı istatistik yöntemi ile yapılan nitelik çıkarma işleminden sonra KNN ve DVM ile yapılan sınıflandırmaların başarı oranları Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1. Tanımlayıcı istatistik yöntemi ile nitelik çıkarma sonucu KNN ve DVM sınıflandırma başarıları

Sınıflandırma Yöntemi	Duyarlılık	Özgüllük	Doğruluk
KNN	%59.57	%55.31	%57.44
DVM	%48.93	%48.93	%48.93

KNN ile yapılan sınıflandırma başarısı %57.44 iken DVM ile yapılan sınıflandırma başarısının %48.93 olduğu görülmüştür.

DTK yaklaşımı ile yapılan nitelik çıkarma işleminden sonra KNN ve DVM ile yapılan sınıflandırmaların başarı oranları Çizelge 4.2.'de gösterilmiştir.

Çizelge 4.2. DTK yaklaşımı ile nitelik çıkarma sonucu KNN ve DVM sınıflandırma başarıları

Sınıflandırma Yöntemi	Duyarlılık	Özgüllük	Doğruluk
KNN	%93.61	%65.95	%79.78
DVM	%93.61	%68.08	%80.85

KNN ile yapılan sınıflandırma işleminin başarısı %79.78 iken DVM ile yapılan sınıflandırmanın başarı oranının %80.85 ile KNN ile yapılan sınıflandırmaya göre daha yüksek olduğu görülmüştür.

HFD ile yapılan nitelik çıkarma işleminden sonra KNN ve DVM ile yapılan sınıflandırma işleminin başarı durumu Çizelge 4.3'te gösterilmiştir.

Çizelge 4.3. HFD ile nitelik çıkarma sonucu KNN ve DVM sınıflandırma başarıları

Sınıflandırma Yöntemi	Duyarlılık	Özgüllük	Doğruluk
KNN	%93.61	%46.80	%70.21
DVM	%51.06	%48.93	%48.93

KNN ile yapılan sınıflandırma işleminde %70.21'lik bir başarı gözlenirken; DVM ile yapılan sınıflandırma işleminde başarı oranı %48.93 olarak gözlenmiştir. Bu başarı oranları HFD ile yapılan nitelik çıkarma işlemiyle elde edilen veri setinde KNN başarısının daha yüksek olduğunu göstermiştir.

Denenen üç öznitelik çıkarma metodundan DTK'nın, sınıflandırma performansını daha çok artırdığı görüldüğü için uygulamanın icrasında DTK yöntemi tercih edilmiştir.

4.3. Boyut Azaltma

Boyut azaltma işlemi iki şekilde yapılmıştır. Bu adımlardan ilki nitelik seçimi ikincisi ise nitelik çıkarımıdır.

Boyut azaltmak için yaygın olarak kullanılan yöntemlerin başında nitelik seçim algoritmaları gelir. Bu adımda bölüm 3.3.1'de anlatılmış olan 7 farklı nitelik seçim algoritması uygulanarak sonuçları karşılaştırılmıştır.

Boyut azaltmak için diğer bir yaygın yöntem nitelik çıkarımıdır. Bu adımda boyut azaltmak için nitelik çıkarımı TBA ile yapılmıştır.

4.3.1. Nitelik seçimi

Öznitelik çıkarma işleminden sonra sınıflandırma öncesi yüksek doğruluk sağlamak için nitelik seçme işlemi uygulanmıştır. Nitelik seçme yöntemiyle ses içerisindeki en anlamlı, sesi en iyi ifade eden niteliklerin seçilmesi hedeflenmiştir. Sesin içerisinde bulunan fakat sesin özelliklerini çok az ya da hiç yansıtmayan niteliklerin sınıflandırma performansını düşürdüğü bilinmektedir. Bu nedenle sınıflandırma performansını artırmak için tüm sesi en iyi ifade eden, sesin özelliklerini en iyi yansıtan nitelikler seçilmiştir. Bu işlem yapılırken sesi en az ifade eden nitelikler elenmiştir. Bu aşamada 7 farklı nitelik seçme metodu uygulanmıştır. Performansı en yüksek olan nitelik seçme metodu tespit edilmeye çalışılmıştır.

İlk olarak Aşırı Öğrenme Makinesi (AÖM) ve Değişim Katsayısına (DK) Dayalı Hızlı Özellik Seçimi Yaklaşımı ile nitelik seçme denenmiştir. Bu yöntemde niteliğin ne kadar iyi bir nitelik olduğu değişim katsayısının değeriyle ölçülür. Düşük değişim katsayısına sahip nitelik en anlamlı nitelik olur. Burada nitelik çıkarma sonucunda elde edilmiş olan 94x5500'lük matrisle ifade edilen nitelik vektörleri algoritma tarafından belirlenen katsayılara göre sıralanmış ve bu sıralama sonucundaki toplam veriden belli miktarda veri seçilmiştir. Sıralamanın temel alınacağı katsayı AÖM'nin DK'ya bölünmesiyle elde edilir. Daha sonra elde edilen bu katsayıya göre

nitelikler sıralanır ve buna göre en iyi nitelik sıralaması yapılmış veri setinden en iyi başarıyı verebilecek şekilde istenen sayıda sütun seçilmiştir. Burada en yüksek başarıyı sağlayan 5 sütun veri en iyi nitelikler olarak seçilmiş olur. Sonuç olarak nitelik çıkarma sonucu elde edilen 94x5500'lük matris 94x5'lik bir matrise dönüştürülebilir. Şekil 4.7'de aşırı öğrenme makinesi ve değişim katsayısına dayalı hızlı özellik seçimi yaklaşımı uygulanarak elde edilen veri seti gösterilmiştir.

	1	2	3	4	5
1	4.9044	6.7329	8.1452	5.2763	5.6132
2	6.8184	5.6448	6.6906	6.2277	6.9317
3	4.8057	5.2396	6.0934	6.3435	6.5390
4	6.3947	6.5385	6.7910	5.6516	7.4432
5	6.8263	5.8872	7.1616	5.1508	7.7026
6	6.1492	6.1799	6.6367	5.9703	6.8035
7	5.1987	6.2048	5.1803	6.8705	6.3350
8	5.1215	5.3678	6.4592	6.5773	5.5999
9	6.1833	6.7399	7.1963	6.3328	6.4853
10	7.5323	7.3348	7.3015	5.0264	6.2134
11	6.4030	5.3009	6.0294	7.2469	6.7511
12	5.2035	6.2933	6.3822	5.7024	7.2760
13	5.9014	6.7831	6.5479	5.5737	5.3452
14	6.8344	3.7670	4.4331	7.2439	6.6596
15	7.2829	7.0873	6.8649	6.6390	6.1971
16	4.8536	5.5920	4.9811	3.9611	6.1481
17	5.2510	5.0259	4.9155	4.4842	5.5133
18	6.6118	6.2932	5.9221	6.1947	6.9457
19	4.9893	5.4450	6.9953	5.0115	6.3571
20	6.9640	6.1978	6.8218	6.5990	5.8891
21	6.1135	5.5418	6.6402	5.2620	7.1586
22	6.8243	5.6125	7.1526	5.7217	6.1946
23	7.5646	7.1179	6.6323	4.8180	5.5453

Şekil 4.7. Aşırı öğrenme makinesi ve değişim katsayısına dayalı hızlı özellik seçimi yaklaşımı sonucu elde edilen veri seti.

Bu nitelik seçme yöntemi sonucu KNN ile sınıflandırma yapıldığında başarı %68.08 olurken, DVM ile sınıflandırıldığında %72.34 olduğu görülmüştür. Bu oran bu nitelik seçme yönteminin trafikteki uyarıcı seslerin olduğu veri seti için yeterince başarılı olmadığını göstermiştir.

İkinci yöntem olarak “RelieFF” nitelik seçme yöntemi uygulanmıştır. Bu yöntemde niteliklerin değeri aralarındaki ilişkiye göre belli olur. Başka bir deyişle niteliğin ait olduğu ve ait olmadığı sınıflardaki niteliklere olan uzaklıklarının ağırlıklandırılmasıyla gerçekleştirilir. Bu uygulamada da sesin özelliklerini en çok taşıyan en anlamlı nitelikleri seçmek için nitelikler arasındaki ilişkiye bakılmıştır. Niteliklerin ağırlıklarına göre sıralanmıştır ve sıralanmış veriden belirli bir eşik değeri veren üstteki nitelikler seçilmiştir. Nitelik çıkarma ile 94x5500'lük bir matrisle ifade edilen veri seti RelieFF nitelik seçme yöntemi sonucu 94x1006'lık bir matrise dönüşmüştür.

RelieFF nitelik seçme metodu ile elde edilen veri, KNN ile sınıflandırma işlemine sokulduğunda %77.65'lik bir başarı gösterirken, DVM ile sınıflandırma yapıldığında %78.72'lik bir sınıflandırma başarısının olduğu görülmüştür. Fakat bu başarı oranı RelieFF nitelik seçme yönteminin bu veri seti için performansının istenen ölçüde olmadığını göstermiştir.

Sistemin oluşturulması sürecinde denenen 3. nitelik seçme yöntemi Fisher Skor yöntemidir. Bu uygulamada bu yöntem, niteliklerin hesaplanan skorlara göre büyükten küçüğe sıralanması ve ardından en üst sıradan başlanarak istenen sayıda niteliğin seçilmesi şeklinde uygulanmıştır. Veri setine Fisher Skor yönteminin uygulanmasıyla nitelikler hesaplanan skorlara göre büyükten küçüğe sıralanmış ve sonrasında en üst sıradan başlanarak istenen sayıda nitelik seçilmiştir. Öznitelik çıkarma sonucu elde edilen 94x5500'lük matris 94x1000'lik bir matrise dönüşmüştür.

Fisher Skor nitelik seçme yöntemi uygulanarak elde edilen veri seti sınıflandırmaya tabi tutulduğunda, sınıflandırma başarısının KNN ile yapılan sınıflandırma işleminde %50.00 olduğu görülürken, DVM ile yapılan sınıflandırma işleminde % 56.38 olduğu görülmüştür. Bu başarı oranı Fisher Skor nitelik seçme yönteminin trafikteki uyarı seslerinden oluşan veri seti için performansının kötü olduğunu göstermiştir.

Uygulamanın ortaya konulması için çalışma sürecinde denenen nitelik seçme yöntemlerinden birisi de Sonsuz Gizli Özellik Seçimi (SGÖS) yöntemidir. Bu yöntemde olası tüm nitelik alt kümeleri göz önüne alınarak işlem yapılır. Nitelik alt kümelerini birleştirerek bağlantıları yol olarak belirler. Her yolun maliyeti ortak düğüm tarafından verilir. Niteliğe ait tüm düğümlerin olasılıkları hesaplanır. Bu uygulamada da SGÖS

nitelik seçme yöntemi uygulanırken her bir niteliğin, diğerlerine göre alaka düzeyi değerlendirilerek nitelik seçimi gerçekleştirilmiştir. Veri setinden en iyi başarıyı verebilecek şekilde istenen sayıda sütun seçilmiştir. Öznitelik çıkarma işleminden sonra 94x5500'lük matris ile ifade edilen ses sinyali SGÖS yöntemi ile nitelik seçme işlemi uygulandıktan sonra 94x1006'lık matrise dönüşmüştür. Öznitelik çıkarma işleminden sonra bu nitelik seçme yöntemi uygulanarak elde edilen yeni veri seti KNN ile sınıflandırmaya tabi tutulduğunda %78.72 oranında bir başarı gösterirken, DVM ile sınıflandırma yapıldığında %77.65 oranında bir sınıflandırma başarısı elde edilmiştir. Bu başarı oranı SGÖS nitelik seçme yönteminin trafikteki uyarıcı seslerden oluşan veri seti için performansının yeterli olmadığını göstermiştir.

Sistemin oluşturulması esnasında sınıflandırma performansını artırmak için denenen nitelik seçme yöntemlerinden beşincisi İçbükey Minimizasyon ile Nitelik Seçimi (İMNS) olarak adlandırılan nitelik seçme yöntemidir. İki sınıflı bir sınıflandırma problemi için veri setindeki değerlerden seçilecek nitelikleri belirlemek için kullanılan bu yöntem ağırlıkların minimizasyonuna dayanır. Veri setinden en iyi başarıyı verebilecek şekilde istenen sayıda sütun seçilmiştir. Öznitelik çıkarma işleminden sonra 94x5500'lük bir matrisle ifade edilen nitelik vektörleri en anlamlı niteliklerin İMNS ile seçilmesinden sonra 94x1006'lık bir matrise dönüşmüştür.

İMNS nitelik seçme yöntemi ile yapılan nitelik seçme işleminden sonra elde edilen veri seti sınıflandırmaya tabi tutulmuştur. Bu sınıflandırma işleminden sonra hem KNN ile hem de DVM ile yapılan sınıflandırma sonucunda başarının %78.72 olduğu gözlenmiştir. Bu başarı oranı İMNS nitelik seçme yönteminin de istenen başarı performansına sahip olmadığını göstermiştir.

Denenen altıncı nitelik seçme yöntemi Yinelemeli Özellik Elemesi (YÖE) olarak adlandırılan nitelik seçme yöntemidir. YÖE yöntemi uygulanırken veriyi en iyi temsil eden en anlamlı nitelikleri bulmak için, önce tüm nitelikler derecelendirilip daha sonra en düşük dereceye sahip nitelikler nitelik kümesinden çıkarılarak bunlar dışında kalan nitelikler seçilir. En yüksek başarı elde edilene kadar bu işleme devam edilir ve nitelik seçimi bu şekilde yapılır. 94x5500'lük bir matris ile ifade edilen veri seti, YÖE nitelik çıkarma yöntemi uygulandıktan sonra 94x1011'lik bir matrise dönüşmüştür.

Veri setine YÖE nitelik seçme yöntemi uygulandıktan sonra veri setinin yeni biçimi sınıflandırma işlemine tabi tutulmuştur. KNN ile sınıflandırılan yeni veri setinde

sınıflandırma başarısının %50.00 olduğu görülürken, DVM ile yapılan sınıflandırma sonucu başarının %53.19 olduğu görülmüştür. Bu sınıflandırma başarısı YÖE nitelik seçme yönteminin trafikteki uyarıcı seslerden oluşan veri seti için performansının düşük olduğunu göstermiştir.

Sistemin geliştirilmesi sırasında denenen son nitelik seçme yöntemi En Küçük Mutlak Çekme ve Seçme Operatörü (EMÇSO) olarak adlandırılan nitelik seçme yöntemidir. Bu yöntem uygulanırken katsayılara göre işlem yapılır. Katsayıları sıfır olan nitelikler en alakasız nitelikler olarak belirlenir. Katsayısı sıfır olmayanlar en iyi, en anlamlı nitelikler olarak seçilir. Katsayısı sıfır olan nitelikler veri setinden atılır. EMÇSO nitelik seçme yöntemi uygulanmadan önce nitelik vektörleri 94x5500'lük bir matris ile ifade edilirken nitelik seçme işleminden sonra 94x1000'lik bir matrise dönüşmüştür.

Son olarak denenen EMÇSO nitelik seçme yöntemi uygulanan nitelik vektörlerinden elde edilen veri seti sınıflandırma işlemine tabi tutulmuştur. Hem KNN hem de DVM ile yapılan sınıflandırma sonucu veri setinde sınıflandırma başarısı %79.78 olarak görülmüştür. Bu başarı oranı EMÇSO nitelik seçme yönteminin de beklenen başarıyı göstermediğini ortaya koymuştur.

Denenen yedi farklı nitelik seçme yönteminin hiçbirinin sınıflandırma performansını yeteri kadar artırmadığı görülmüştür. Çizelge 4.4'de uygulanan nitelik seçme yöntemlerinin sınıflandırma başarısı gösterilmiştir.

Çizelge 4.4. Nitelik seçme yöntemlerinin başarı oranları

Nitelik Seçme Yöntemi	Duyarlılık	Özgüllük	Doğruluk
Yinelemeli Özellik Elemesi (YÖE)	%21.27	%85.10	%53.19
Fisher Skor	%25.53	%87.23	% 56.38
Aşırı Öğrenme Makinesi ve Değişim Katsayısına Dayalı Hızlı Özellik Seçimi Yaklaşımı	%72.34	%70.21	%72.34
Sonsuz Gizli Özellik Seçimi (SGÖS)	%93.61	%63.82	%78.72
ReliefF	%93.61	%63.82	%78.72
İçbükey Minimizasyon ile Nitelik Seçimi (İMNS)	%93.61	%63.82	%78.72
En Küçük Mutlak Çekme ve Seçme Operatörü (EMÇSO)	%89.36	%70.21	%79.78

4.3.2. Nitelik çıkarımı

Nitelik seçme yöntemleriyle yeterli başarı elde edilemeyince nitelik çıkarımı işlemi yapılmaya karar verilmiştir. Özellik çıkarımı için TBA algoritması kullanılmıştır. TBA ile özellikler çıkarılarak veri seti, en iyi özellikler en başa gelecek şekilde düzenlenmiştir. TBA ile çıkarılan en iyilerinin en başa alındığı özelliklerin olduğu veri setinden baştan başlanarak belli sayıda özellik seçilmiştir. Hem DTK ile yapılan öznitelik çıkarma işleminden sonra hem de HFD ile yapılan nitelik çıkarma işleminden sonra TBA işlemi uygulanmıştır. Bu özellik seçimi sınıflandırmayla test edilip sınıflandırma performansını en çok artıran sütun sayısına göre yapılmıştır. Denemeler sonucunda en iyi performansı veren 15 sütunluk bir seçimdir.

DTK ile yapılan öznitelik çıkarma işlemiyle 94x5500'lük matris ile ifade edilen ses verisi TBA işleminin ardından 94x93'lük bir matrise dönüşmüştür. TBA ile en iyilerin en başta olduğu 94x93'lük matris ile ifade edilen veri setinden 15 sütun seçilmesiyle 94x15'lik bir matrise dönüşmüştür.

DTK ile öznitelikleri çıkarılıp boyutu azaltılan veri sınıflandırma performansını görmek için sınıflandırma işlemine tabi tutulmuştur.

Boyut azaltma işlemi sonucu elde edilen veri seti sırasıyla hem KNN hem de DVM ile sınıflandırmaya tabi tutulmuştur. Boyut azaltma işleminden sonra KNN ve DVM ile yapılan sınıflandırmaların başarı oranları Çizelge 4.5’de gösterilmiştir.

Çizelge 4.5. DTK sonrası boyut azaltma işlemi sonucu KNN ve DVM sınıflandırma başarıları

Sınıflandırma Yöntemi	Duyarlılık	Özgüllük	Doğruluk
KNN	%93.61	%65.95	%79.78
DVM	%95.74	%70.21	%82.97

DTK sonrası boyut azaltmada nitelik çıkarımı işleminden sonra KNN ile yapılan sınıflandırma sonucu başarı oranının boyut azaltma işlemi uygulanmamış sadece öznitelik çıkarma işlemi yapılmış veri setiyle aynı olduğu görülmüştür. Her iki durumda da başarı oranının %79.78 olduğu görüldü. Boyut azaltmada nitelik çıkarımı işlemi uygulanmış aynı veri seti DVM ile sınıflandırma işlemine tabi tutulduğunda başarı oranının %82.97 olduğu görülmüştür. Nitelik çıkarımı işlemi ile sağlanan sınıflandırma başarısının daha önce denenen 7 nitelik seçme yönteminden daha yüksek olduğu görülmüştür.

DTK sonrası uygulanan TBA işleminden sonra HFD ile yapılan öznitelik çıkarma sonucu elde edilmiş veri seti de TBA işlemine tabi tutulmuştur. HFD ile elde edilen 94x5500’lük matris ile ifade edilen veri seti DTK’da da olduğu gibi 94x93’lük bir matrise dönüşmüştür. En iyi niteliklerin en başta olduğu 94x93’lük matristen 15 sütun seçilmesiyle veri seti 94x15’lik bir matrise dönüşmüştür.

HFD ile öznitelikleri çıkarılıp TBA ile boyutu azaltılan veri önce KNN daha sonra DVM ile sınıflandırma işlemine tabi tutulmuştur ve elde edilen başarı oranları Çizelge 4.6’da gösterilmiştir.

Çizelge 4.6. HFD sonrası boyut azaltma işlemi sonucu KNN ve DVM sınıflandırma başarıları

Sınıflandırma Yöntemi	Duyarlılık	Özgüllük	Doğruluk
KNN	%87.23	%65.95	%76.59
DVM	%48.93	%48.93	%48.93

KNN başarısının TBA uygulanmamış sadece HFD ile öznelik çıkarma işlemi yapılmış veri setine göre arttığı ve başarı oranının %76.59 olduğu görülürken, DVM başarısının aynı kalarak %48.93 olduğu görülmüştür. Bu başarı oranları HFD ile elde edilen veri setinde KNN'in daha başarılı olduğunu göstermiştir. Bununla birlikte DTK sonrası TBA'ya tabi tutularak elde edilen veri setinin daha başarılı olduğunu göstermiştir.

4.4. Sınıflandırma

Sistemin oluşturulması sürecinde denenen ve kullanılan tüm nitelik çıkarma, nitelik seçme ve boyut azaltma yöntemleri KNN ve DVM ile sınıflandırılarak başarıları ölçülmüştür. Ve başarı ölçülürken yapılan tüm sınıflandırma işlemlerinde 2 Katlı Çapraz Doğrulama (2-Fold Cross Validation) uygulanmıştır. Çizelge 4.7 ve çizelge 4.8'de sistemin oluşturulması aşamasında denenen ve kullanılan tüm yöntemlerin KNN ve DVM ile sınıflandırma işlemindeki başarıları gösterilmiştir.

Çizelge 4.7. KNN sınıflandırma başarıları

Yöntem	Duyarlılık	Özgüllük	Doğruluk
Tanımlayıcı İstatistik İle Öznelik Çıkarma	%59.57	%55.31	%57.44
DTK Yaklaşımı ile Öznelik çıkarma	%93.61	%65.95	%79.78
HFD İle Öznelik Çıkarma	%93.61	%46.80	%70.21
DTK + Aşırı Öğrenme Makinesi ve Değişim Katsayısına Dayalı Hızlı Özellik Seçimi Yaklaşımı	%68.08	%63.82	%68.08
DTK + ReliefF	%91.48	%63.82	%77.65
DTK + Fisher Skor	%00.00	%100.00	%50.00
DTK + SGÖS	%93.61	%63.82	%78.72
DTK + İMNS	%93.61	%63.82	%78.72
DTK + YÖE	%00.00	%100.00	%50.00
DTK + EMÇSO	%89.36	%70.21	%79.78
DTK + TBA	%93.61	%65.95	%79.78
HFD + TBA	%87.23	%65.95	%76.59


Çizelge 4.8. DVM sınıflandırma başarıları

Yöntem	Duyarlılık	Özgüllük	Doğruluk
Tanımlayıcı İstatistik İle Öznitelik Çıkarma	%48.93	%48.93	%48.93
DTK Yaklaşımı ile Öznitelik çıkarma	%93.61	%68.08	%80.85
HFD İle Öznitelik Çıkarma	%51.06	%48.93	%48.93
DTK + Aşırı Öğrenme Makinesi ve Değişim Katsayısına Dayalı Hızlı Özellik Seçimi Yaklaşımı	%72.34	%70.21	%72.34
DTK + ReliefF	%93.61	%63.82	%78.72
DTK + Fisher Skor	%25.53	%87.23	%56.38
DTK + SGÖS	%93.61	%63.82	%77.65
DTK + İMNS	%93.61	%63.82	%78.72
DTK + YÖE	%21.27	%85.10	%53.19
DTK + EMÇSO	%89.36	%70.21	%79.78
DTK + TBA	%95.74	%70.21	%82.97
HFD + TBA	%48.93	%48.93	%48.93

Çizelge 4.7 ve Çizelge 4.8’de de görüldüğü gibi genel olarak DVM ile yapılan sınıflandırmaların başarı oranının daha yüksek olduğu görülmüştür. Beklenenin aksine bazı yöntemlerde KNN daha yüksek başarıya sahip olsa da çoğunlukla DVM’nin daha başarılı olduğu tespit edilmiştir. Nitelik seçme yöntemlerinden aşırı öğrenme makinesi ve değişim katsayısına dayalı hızlı özellik seçimi yaklaşımında program her çalıştırıldığında farklı nitelikleri daha anlamlı seçtiği için sabit olmayan bir başarı oranı gözlenirken aynı zamanda seçilen değerlere bağlı olarak KNN ve DVM’nin başarılı olma durumu da değişmektedir. Çizelgede örnek bir uygulama sonucu verilmiştir. KNN ve DVM ile yapılan sınıflandırmalar DVM’nin daha başarılı olduğunu göstermiştir.

4.5. Ses Yönünün Belirlenmesi

Profesyonel kayıt stüdyosunda iki mikrofon ile alınan ses kaydı ile yön tespiti yapılmaya çalışılmıştır. Biri sağ biri solda bulunan iki mikrofon ile yapılan testte sesin hangi yönden geldiği belirlenmiştir. İki mikrofon bulunduğu için sadece sağ sol tespiti yapılmıştır. Ancak 4 mikrofon olduğunda aynı şekilde yön tespiti sağ ön, sol arka vb. şeklinde yapılabilecektir. Stüdyo ortamında bir ambulans sesi üzerinden yapılan denemede 51 saniye boyunca yapılan ses kaydı bilgisayar ortamına alınmıştır. Şekil 4.8’de bu ses sinyali gösterilmiştir.



Şekil 4.8. İki mikrofonda 51 saniyelik ses sinyali.

Şekil 4.8'deki 2 farklı renk ile kayıta 2 farklı kanaldan alınan ses gösterilmektedir.

Basit bir şekilde ses yönü anlaşılmasına çalışıldığında dahi düşünülecek ilk şey iki mikrofonda hangisinde ses daha yüksek şiddette alınmış ise sesin ona daha yakın olduğudur. Bu prensipten yola çıkılarak mikrolondaki ses genlikleri incelenmiştir. Veri seti 2 saniyelik seslerden oluştuğu için 2 saniyelik sesler üzerinden ses yönü bilgisi bulunmaya çalışılmıştır. 2 farklı mikrofonda alınan ses kaydı 2 sütunlu bir matris ile ifade edilir. Şekil 4.9'da örnek bir ses sinyalini ifade eden farklı kanallara ait sayısal değerler gösterilmiştir.


	Sol Mikrofon	Sağ Mikrofon
1	-0,041595459	0,005187988
2	-0,03012085	0,011413574
3	-0,000762939	0,014434814
4	0,022735596	0,02041626
5	0,036437988	0,015991211
6	0,032714844	0,010528564
7	0,025115967	-0,001434326
8	0,015991211	-0,007232666
9	0,015563965	-0,011871338
10	0,017883301	-0,01449585
11	0,029174805	-0,003417969
12	0,039886475	0,002075195
13	0,049560547	0,004669189
14	0,046508789	0,005462646
15	0,034545898	0,006835938
16	0,018035889	0,007324219
17	0,004119873	0,006347656
18	-0,006713867	-0,000854492
19	-0,012512207	-0,005584717
20	-0,015258789	-0,005950928
21	-0,01071167	-0,005737305
22	-0,004516602	-0,002044678
23	0,000640869	0
24	0,001953125	0,000366211
25	0,002471924	0,002471924

Şekil 4.9. İki mikrofonlu 2 saniyelik ses sinyali.


Şekil 4.9’da da görüldüğü gibi 2 farklı mikrofonla yapılan ses kaydı 2 sütunla ifade edilen bir matrise dönüştüğünde matristeki değerlere bakılarak sesin hangi yönden geldiği tespit edilebilmektedir. Burada birinci sütun sol taraftaki mikrona ait değerleri gösterirken ikinci sütun sağ taraftaki mikrofonu ait değerleri göstermektedir. Her 2 mikrofonu ait ses sinyalindeki genlik değerleri toplanarak toplam değerler karşılaştırılmıştır. Sesin, genlik değerleri toplamı büyük olan mikrofonu yakın olduğu, yani sesin o mikrofonun olduğu yönden geldiği anlaşılmıştır.

Şekil 4.9’daki 2 saniyelik örnek ses kaydına ait sağ ve sol mikrofon değerleri toplamı karşılaştırıldığında sol mikrofonu ait genlik değerleri toplamının daha büyük olduğu görülmektedir. Bu durum sesin sol taraftan geldiğini göstermektedir.

Şekil 4.9’da sayısal hali gösterilmiş olan ses sinyalinin sol ve sağ mikrofonu ait grafikleri şekil 4.10 ve şekil 4.11’de gösterilmiştir.



Şekil 4.10. Sol taraftaki mikrofonu ait ses sinyali.



Şekil 4.11. Sağ taraftaki mikrofonu ait ses sinyali.

Şekil 4.10 ve şekil 4.11’de gösterilen grafiklerdeki genlik değerlerine bakıldığında sol mikrofondaki genlik değeri 0.1 civarlarındayken sağ mikrofondaki genlik değerinin 0.05 civarlarında olduğu görülmektedir. Bu değerlerden de anlaşıldığı gibi sol mikrofondaki genlik değerlerinin sağ mikrofondan fazla olduğu görülmektedir. Bu durum da sesin sol mikrofonu yakın olduğunu açıkça göstermektedir.

5. TARTIŞMA VE SONUÇ

İşitme engellilerin trafikte rahat araç kullanmalarını sağlamak amacıyla oluşturulmak istenen ses tanıma sistemi tasarlanırken ilk olarak kaynak taramaları yapılmıştır. Sistemdeki ses tanıma sürecinin teknik olarak daha çok sesli komut tanıma sistemlerine benzediği görülmüştür. İşitme engellilerin uyarılması gereken olumlu sesler ve uyarıya gerek olmayan olumsuz sesler belirlenerek kişisel bilgisayar yardımıyla kayıtlar alınıp kategorilerine göre ayrılmıştır. Olumlu ve olumsuz sesler belirlenirken, trafikte geçiş önceliği bulunan ambulans, polis, itfaiye gibi araçların siren sesleri olumlu sesler olarak belirlenmiştir. Trafik gürültüsü, korna sesi, müzik sesi ve tarikte bulunan olumlu kategorisine girmeyen diğer sesler olumsuz sesler olarak belirlenmiştir. Ardından performanslı bir ses tanıma gerçekleştirebilmek için birçok yöntem test edilerek başarıları karşılaştırılmıştır. Ses kayıtları bilgisayar ortamına alındıktan sonra sayısallaştırılarak öznitelik çıkarma yöntemlerine tabi tutulmuştur. Üç farklı öznitelik çıkarma yöntemi denenerek ses tanımaya olan katkısı karşılaştırılmıştır. Bu nitelik çıkarma yöntemlerinden ilki Tanımlayıcı İstatistik, ikincisi ses tanıma sistemlerinde yaygın olarak kullanılan DTK yaklaşımıyla öznitelik çıkarma işlemiyken üçüncüsü ise HFD ile öznitelik çıkarma işlemidir. Bu üç nitelik çıkarma yöntemi KNN ve DVM ile sınıflandırma işlemine tabi tutularak bu yöntemlerin ses tanımaya olan katkısı tespit edilmiştir. Tanımlayıcı istatistik yönteminin başarısına bakıldığında; KNN ile yapılan sınıflandırma başarısı %57.44 iken beklenenin aksine DVM ile yapılan sınıflandırma başarısının %48.93 olduğu görülmüştür. Her iki sınıflandırmanın sonuçları değerlendirildiğinde başarı oranının düşük olduğu ve bu öznitelik çıkarma yönteminin başarısız olduğu anlaşılmıştır.

DTK yaklaşımıyla öznitelik çıkarma işleminin başarısına bakıldığında ise; KNN için %79.78, DVM için %80.85 olduğu görülmüştür.

HFD kullanılarak yapılan öznitelik çıkarma işleminin başarısı incelendiğinde; KNN ile yapılan sınıflandırma başarısının %70.21 olduğu görülürken DVM ile yapılan sınıflandırma başarısının %48.93 olduğu görüldü. Bu üç öznitelik çıkarma yöntemi karşılaştırıldığında DTK yaklaşımı ile yapılan nitelik çıkarma yönteminin daha başarılı olduğu görülmüştür. Bu başarı sonucu, trafikteki geçiş önceliği olan araçların siren

seslerinin tanınması için nitelik çıkarma yöntemi olarak DTK yaklaşımıyla devam edilmesi gerektiğini göstermiştir.

Öznitelik çıkarma işlemi için DTK yaklaşımına karar verildikten sonra veri boyutunun büyüklüğü dikkat çekmektedir. Bu durumda boyut azaltma işlemi uygulanması uygun görülmüştür. Boyut azaltma için öncelikli nitelik seçme uygulanmıştır. 7 farklı nitelik seçme yöntemi denenmiştir. Ancak nitelik seçme yöntemi sınıflandırma başarısında artırıcı etki göstermediği gibi sınıflandırma başarısının düşmesine sebep olduğu görülmüştür. Denenen nitelik seçme yöntemlerinden en yüksek başarıya sahip olan yöntemin %79.78 ile EMÇSO olduğu görülmüştür. Ve bu yöntem ile sağlanan nitelik seçiminin ardından yapılan sınıflandırma sonucunda başarı oranının %79.78 olduğu görüldü. Hiç nitelik seçme işlemi yapılmamış sadece öznitelik çıkarma işlemi yapılmış veri seti sınıflandırmaya tabi tutulduğunda %80.85'lik bir başarı oranı elde edilmiştir. Bu durum nitelik seçme işleminin trafikteki uyarıcı seslerden oluşan veri seti için kullanımının yeterince fayda sağlamadığını göstermiştir.

Boyut azaltma ile ilgili ikinci yaklaşım olarak nitelik çıkarımı uygulanmıştır. Bunun için seçilen yöntem yaygın bir kullanım alanı olan TBA'dır. DTK ile öznitelik çıkarma işleminden sonra boyut azaltmak için uygulanan TBA işlemi KNN ve DVM ile sınıflandırmaya tabi tutularak değerlendirilmiştir. Elde edilen veri seti KNN ile sınıflandırmaya tabi tutulduğunda başarı oranı %79.78 olurken; DVM ile sınıflandırmaya tabi tutulduğunda başarı oranının %82.97 olduğu görülmüştür.

DTK ile öznitelik çıkarılıp TBA ile boyut azaltılarak elde edilen veri setinin başarısı incelendikten sonra, HFD ile öznitelik çıkarılarak elde edilen veri setinin TBA uygulandığında başarısının DTK ile yapılandırma fazla olup olamayacağı test edilmek istenmiş ve veri seti sınıflandırmaya tabi tutulmuştur. KNN ile yapılan sınıflandırma sonucunda sınıflandırma başarısı %76.59 olurken; DVM ile yapılan sınıflandırma başarısının %48.93 ile TBA uygulanmadan önceki başarı oranıyla aynı olduğu görülmüştür.

Bu çalışma sonucunda kullanılan yöntemler değerlendirildiğinde nihai olarak DTK, TBA ve DVM'den oluşan ses tanıma sistemi en başarılı alternatif olarak belirlenmiştir ve bu sistemin yapısı Şekil 4.1'de verilmiştir. Ayrıca genel olarak DVM yönteminin KNN yöntemine göre daha başarılı olduğu görülmüştür.

Sonuç olarak bu çalışma kendinden sonraki çalışmalara örnek olabilecek niteliktedir. Gerekli düzenlemeler yapıp araçlara montajlanabilir hale gelen bir donanımın dönüştürüldüğü takdirde bir çok işitme engelli bireyin hayatını kolaylaştıracaktır. Daha detaylı, ses tanıma oranı daha yüksek bir sistem oluşturulmak istendiğinde yol gösterici nitelikte olacaktır. Korna seslerinin de olumlu ses kategorisine alınarak araca yakın mesafedeki korna seslerinin de tespit edilebilmesi gibi yeni fikirlerin oluşmasına imkân sağlayacak bir çalışmadır.

Bu çalışma daha da geliştirilebilir. Ses tanıma işlemi için farklı öznelik çıkarma yöntemleri denenerek daha yüksek başarılı ses tanıma gerçekleştirilebilir. Derin öğrenme kullanılarak daha gelişkin bir sistem ortaya konulabilir. Yapılan çalışmalardan destek alınarak sesin özelliklerini en çok taşıyan ve en anlamlı niteliklerin seçildiği yeni bir yöntem ortaya konulabilir. Buna bağlı olarak daha hassas öznelik çıkarma ve boyut azaltma işlemi gerçekleştirilerek daha kaliteli bir ses tanıma işlemi gerçekleştirilebilir. Bilgisayar ortamında yapılan ses tanıma işlemi araçlarda kullanılacak forma getirilerek bir ekran yardımıyla kullanıcıya ses ve yön bilgisi ile alakalı görsel bir uyarı verilebilir.



KAYNAKLAR

- Altun H., Polat, G., 2008. Sınıflandırma problemlerinde sınıflandırıcı performanslarının karşılaştırılması: Eleştiri ve Öneriler On the comparison of classifiers' performance in classification problems: Critiques and Suggestions.
- Anonim, 2018. DVM (Support Vector Machines) – Karar Destek Makineleri 1. Bölüm. <https://www.datafloyd.com/tr/DVM-support-vector-machines-karar-destek-makineleri-1-bolum/>. Erişim Tarihi: 17.05.2019.
- Aydın, Ö., 2005. *Yapay Sinir Ağlarını Kullanarak Bir Ses Tanıma Sistemi Geliştirilmesi* (Master's thesis). TÜ, Fen Bilimleri Enstitüsü, Edirne.
- Bala, A., Kumar, A., Birla, N., 2010. Voice command recognition system based on MFCC and DTW. *International Journal of Engineering Science and Technology*, 2(12): 7335-7342.
- Başaran, S., 2007. *Yapay Sinir Ağları Kullanarak Konuşmacı Tanıma* (Yüksek Lisans Tezi). UÜ, Fen Bilimleri Enstitüsü, Bursa.
- Budak, H., 2018. Özellik seçim yöntemleri ve yeni bir yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 22: 21-31.
- Bradley, P. S., and Mangasarian O. L., 1998. Feature selection via concave minimization and support vector machines. *ICML*. 98.
- Campbell, W. M., Assaleh, K. T., Broun, C. C., 2002. Speaker Recognition with Polynomial Classifiers. *IEEE transactions on speech and audio processing*, 10(4): 205-212.
- Campbell, W. M., Campbell, J. P., Reynolds, D. A., Singer, E., Torres-Carrasquillo, P. A., 2006. Support vector machines for speaker and language recognition. *Computer Speech & Language*, 20(2-3): 210-229.
- Caner, M., Üstün, S. V., 2011. Yapay sinir ağları ile konuşmacı kimliğini tanıma uygulaması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 12(2): 279-284.
- Cortes, C., Vapnik, V., 1995. Support-vector networks. *Machine Learning*, 20(3): 273-297.
- Coşkun, C., Baykal, A., 2011. Veri madenciliğinde sınıflandırma algoritmalarının bir örnek üzerinde karşılaştırılması. *Akademik Bilişim 2011*. 1-8.
- Dede, G., Sazlı, M. H., 2010. Biyometrik sistemlerin örüntü tanıma perspektifinden incelenmesi ve ses tanıma modülü simülasyonu. *EEBM Ulusal Kongresi*.
- Elgün, U. G., 2019. *Biyoinformatik Veri Sınıflandırma Problemleri İçin Boyut İndirgemeye Öznitelik Seçimi Yaklaşımlarının Gerçekleştirilmesi* (Yüksek Lisans Tezi). EÜ, Fen Bilimleri Enstitüsü, Kayseri.
- Ertuş, F., Hanilçi, C., 2007. Konuşmacı tanıma sistemi için yeni bir sınıflandırıcı a new classifier for speaker identification system. http://www.emo.org.tr/ekler/1c207d3fccca3a1_ek.pdf. TMMOB Elektrik Mühendisleri Odası, Ankara. Erişim Tarihi: 04.05.2019.
- Ertuğrul, Ö. F., Tağluk, M. E., 2017. A fast feature selection approach based on extreme learning machine and coefficient of variation. *Turkish Journal of Electrical Engineering & Computer Sciences* 25(4): 3409-3420.
- Ertürk, S., 2009. *Sayısal İşaret İşleme*. Birsen Yayınevi, İstanbul.
- Eskidere, Ö., 2012. A comparison of feature selection methods for diagnosis of parkinson's disease from vocal measurements. *Sigma*, 30: 402-414.

- Guyon, I., Weston, J., Barnhill, S., Vapnik, V., 2002. Gene selection for cancer classification using support vector machines. *Machine Learning*, **46**(1-3), 389-422.
- Hanilçi, C., 2007. *Konuşmacı Tanıma Yöntemlerinin Karşılaştırmalı Analiz* (Yüksek Lisans Tezi). UÜ, Fen Bilimleri Enstitüsü, Bursa.
- Hanilçi, C., 2013. *Konuşmacı Tanımadaki Map Uyarlamalı Sınıflandırıcılar* (Doktora Tezi). UÜ, Fen Bilimleri Enstitüsü, Bursa.
- Harmancı, S., 2016. <http://www.hurriyet.com.tr/isitme-engelli-ogrencilere-isaretdiliyle-trafi-40274838>. DHA, Amasya. Erişim Tarihi: 30.04.2019.
- İnal, M., 2001. *Yapay Sinir Ağları Tabanlı Konuşmacı Tanıma* (Doktora Tezi). KÜ, Fen Bilimleri Enstitüsü, Kocaeli.
- Karacalarlı, U., 2018. *Destek Vektör Makinesi (Dvm) Sınıflandırma Metodu Kullanan Saldırı Tespit Sistemlerinin Performansının Özellik Seçimi İle Artırılması* (Yüksek Lisans Tezi). EÜ, Fen Bilimleri Enstitüsü, İzmir.
- Karakoyun, M., Hacıbeyoğlu, M., 2014. Biyomedikal veri kümeleri ile makine öğrenmesi sınıflandırma algoritmalarının istatistiksel olarak karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, **16**(48), 30-42.
- Kaynar, O., Arslan, H., Görmez, Y., Işık, Y. E., 2018. Makine öğrenmesi ve öznetelik seçim yöntemleriyle saldırı tespiti. *Bilişim Teknolojileri Dergisi*, **11**(2), 175-185.
- Kira, K., Rendell L. A., 1992. A practical approach to feature selection. *Machine Learning Proceedings. Morgan Kaufmann*, 249-256.
- Liu, H., Motoda, H., 2007. Computational methods of feature selection. *CRC Press*.
- Muda, L., Begam, M., Elamvazuthi, I., 2010. Voice recognition algorithms using mel frequency cepstral coefficient (MFCC) and dynamic time warping (DTW) techniques. *arXiv preprint arXiv.1003.4083*.
- Pilavcılar, İ. F., 2007. *Metin Madenciliği İle Metin Sınıflandırma* (Yüksek Lisans Tezi). YTÜ, Fen Bilimleri Enstitüsü, İstanbul.
- Roffo, G., Melzi, S., Castellani, U., Vinciarelli, A., 2017. Infinite latent feature selection: A probabilistic latent graph-based ranking approach. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 1398-1406.
- Senoussaoui, M., Kenny, P., Dehak, N., Dumouchel, P., 2010. An i-vector extractor suitable for speaker recognition with both microphone and telephone speech. *In Odyssey* (6).
- Seyrek, İ. H., Ata, H. A., 2010. Veri zarflama analizi ve veri madenciliği ile mevduat bankalarında etkinlik ölçümü. *Journal of BRSA Banking & Financial Markets*. 4(2).
- Sezer, E., 2018. *Sınıflandırma Sorunu İçin En Uygun Değişken Alt Kümesi Seçimi Üzerine Bir Uygulama* (Yüksek Lisans Tezi). MÜ, Sosyal Bilimler Enstitüsü, İstanbul.
- Şentürk, Z., 2015. *Ayrışık Sözcük Tabanlı Türkçe Konuşmacı Tanıma Sistemi Geliştirme Ve Anahtar Kelime Seçiminin Konuşmacı Tanıma Performansına Etkisinin İncelenmesi*. (Yüksek Lisans Tezi). GÜ, Fen Bilimleri Enstitüsü, Ankara.
- Taşcı, E., Onan, A., 2016. K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*.

- TÜİK, 2016. http://www.tuik.gov.tr/PreTablo.do?alt_id=1017. Türkiye İstatistik Kurumu, Ankara. Erişim Tarihi: 30.04.2019.
- Uğuz, H., Arslan, A., 2010. A new approach based on discrete hidden Markov model using Rocchio algorithm for the diagnosis of the brain diseases. *Digital Signal Processing*, 3(20): 923-934.
- Ünsalan, C., Erçil, A., 1998. Comparison of feature selection algorithms a new performance criteria for feature selection. *Proceedings of IEEE SIU'98*, 60-65.
- Vogt, T., André, E., Bee, N., 2008. EmoVoice—A framework for online recognition of emotions from voice. *In International Tutorial and Research Workshop on Perception and Interactive Technologies for Speech-Based Systems* (188-199). Springer, Berlin, Heidelberg.
- Yakut, Ö., 2018. *Ekg İşaretindeki Aritmilerin Yumuşak Hesaplama Algoritmaları Kullanılarak Sınıflandırılması* (Doktora Tezi). KÜ, Fen Bilimleri Enstitüsü, Kocaeli.





ÖZ GEÇMİŞ

1992 yılında Bitlis'in Ahlat ilçesinde doğdu. İlk, orta ve lise öğrenimini Van'da tamamladı. 2010 yılında Fırat Üniversitesi Bilgisayar Mühendisliği Bölümüne başlayarak 2014 yılında mezun oldu. Üniversiteden mezun olduğu yıl 3 ay Elazığ'da özel bir firmada çalıştıktan sonra 2015 yılında Van'a dönerek Bilim Sanayi ve Teknoloji Bakanlığı Teknogirişim Sermayesi Desteği ile projesine destek alıp YYÜ Teknokent'te kendi firmasını kurdu. Bir yıl süreli olan projesini başarıyla tamamlayarak başarı belgesi aldı. Proje bitiminden sonra kendi firmasıyla beraber Van İŞGEM'de yürütülmekte olan AB Projesinde 2017 Nisan ayında çalışmaya başlayarak, 8 ay boyunca Junieur Uzman olarak çalıştı. 2018 yılı Ocak ayında çalışmaya başladığı Van Su ve Kanalizasyon İdaresinde halen çalışmaya devam etmektedir. 2015 yılında Van Yüzüncü Yıl Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalında Tezli Yüksek Lisans eğitimine başladı.

T.C
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU

Tarih: 19/07/2019

Tez Başlığı / Konusu: Doğrusal Tahmini Kodlama Yöntemi Kullanılarak Trafikteki Uyarıcı Seslerin Tespiti

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 24 sayfalık kısmına ilişkin, 19/07/2019 tarihinde tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 1 (bir) dir.

Uygulanan filtreler aşağıda verilmiştir:

- Kabul ve onay sayfası hariç,
- Teşekkür hariç,
- İçindekiler hariç,
- Simge ve kısaltmalar hariç,
- Gereç ve yöntemler hariç,
- Kaynakça hariç,
- Alıntılar hariç,
- Tezden çıkan yayımlar hariç,
- 7 kelimedenden daha az örtüşme içeren metin kısımları hariç (Limit inatch size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.


19/07/2019

Adı Soyadı: Cansu AKYÜREK ANACUR

Öğrenci No: 159101012

Anabilim Dalı: Elektrik Elektronik Mühendisliği ABD

Programı:

Statüsü: Y. Lisans

Doktora

DANIŞMAN ONAYI
UYGUNDUR

Doç. Dr. Ridvan SARAÇOĞLU

ENSTİTÜ ONAYI
UYGUNDUR

Doç.Dr.Serhat KARACA
Enstitü Müdür Yrd.

(Unvan, Ad Soyad, İmza)