

**KALP SESLERİ KULLANILARAK
KİŞİ TANIMA**

Ferda DAL

Yüksek Lisans Tezi

Elektrik Elektronik Mühendisliği Anabilim Dalı

Haberleşme Bilim Dalı

Yrd. Doç. Dr. İ. Yücel ÖZBEK

2015

Her hakkı saklıdır

**ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

KALP SESLERİ KULLANILARAK KİŞİ TANIMA

Ferda DAL

**ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
Haberleşme Bilim Dalı**

**ERZURUM
2015**

Her hakkı saklıdır



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



TEZ ONAY FORMU

KALP SESLERİ KULLANILARAK KİŞİ TANIMA

Yrd. Doç. Dr. İ.Yücel ÖZBEK danışmanlığında, Ferda DAL tarafından hazırlanan bu çalışma 25/12/2015 tarihinde aşağıdaki jüri tarafından Elektrik Elektronik Mühendisliği Anabilim Dalı – Haberleşme Bilim Dalı'nda yüksek lisans tezi olarak **oybirliği/oy çokluğu (3./3)** ile kabul edilmiştir.

Başkan : Yrd. Doç. Dr. İ. Yücel ÖZBEK

İmza :

Üye : Yrd. Doç. Dr. E.Argun ORAL

İmza :

Üye : Yrd. Doç. Dr. Çağlar DUMAN

İmza :

Yukarıdaki sonuç;

Enstitü Yönetim Kurulu...31/12/2015...tarih ve 54/1748...nolu kararı ile onaylanmıştır.

Prof. Dr. Ertan YILDIRIM
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ÖZET

Yüksek Lisans Tezi

KALP SESLERİ KULLANILARAK KİŞİ TANIMA

Ferda DAL

Atatürk Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı
Haberleşme Bilim Dalı

Danışman: Yrd. Doç. Dr. İ. Yücel ÖZBEK

Bu tez çalışmasının temel amacı, kişilere ait kalp sesleri kullanılarak cinsiyet ve yaş sınıfı tanıma yapabilmek ve yeni bir biyometrik tanıma önerebilmektir.

Cinsiyet tanıma işleminde, Gauss Karışım Modeli (GKM) ve Destek Vektör Makineleri (DVM) kullanılarak test edilen kişinin bayan ya da erkek olduğuna karar verilir. Yaş tanıma işleminde ise bireyler genç (<30), orta yaşlı (30-50) ve yaşlı (>50) olmak üzere üç farklı sınıfa ayrılır ve Destek Vektör Makineleri (DVM) kullanılarak test edilen kişinin genç, orta yaşlı ya da yaşlı olduğuna karar verilir.

Veri tabanında 49'u bayan olmak üzere toplam 205 kişiye ait kalp sesi sinyali bulunmaktadır. Bu veri tabanı kullanılarak yapılan çalışmalarda, cinsiyet tanıma işleminde Gauss Karışım Modeli (GKM) kullanılarak elde edilen başarı %87,75 iken, Destek Vektör Makineleri (DVM) kullanılarak elde edilen başarı %93,87'dir. Yaş sınıfı tanıma işlemindeki başarı ise %78,28'dir.

2015, 36 sayfa

Anahtar Kelimeler: Kalp Sesi, Cinsiyet Tanıma, Yaş Sınıfı Tanıma, Gauss Karışım Modeli, Destek Vektör Makineleri

ABSTRACT

Master Thesis

RECOGNIZING PEOPLE USING HEART SOUNDS

Ferda DAL

Atatürk University
Graduate School of Natural and Applied Sciences
Department of Electric and Electronic Engineering
Department of Telecommunication

Supervisor: Asst. Prof. Dr. İ. Yücel ÖZBEK

The basis purpose of this thesis is to do gender and age classification detection using heart sounds and suggest a new biometric.

For gender detection, tested person is determined as male or female using Gauss Mixture Model (GMM) and Support Vector Machine (SVM). For age classification detection, individuals are separated three classes in for young, adult and senior and, tested person is determined as young, adult or senior using Support Vector Machine (SVM).

In the database, there are two hundred five individuals's heart sounds and forty nine of these belong to women. In performed studies using this database, while the obtained success for gender detection using Gauss Mixture Model (GMM) is 87,75%, the obtained success for gender detection using Support Vector Machine (SVM) 93,87%. The obtained success for age classification detection is 78,28%.

2015, 36 pages

Keywords: Heart Sound, Gender Detection, Age Classification Detection, Gaussian Mixture Model, Support Vector Machines

TEŞEKKÜR

Yüksek lisans tez çalışmamın yürütülmesinde tecrübelerini ve bilgilerini esirgemeyen çok değerli hocam Sayın Yrd. Doç. Dr. İ. Yücel ÖZBEK'e ve çalışmamın her aşamasında yardımlarını esirgemeyen değerli arkadaşım Sema COŞĞUN'a teşekkür ediyorum.

Ayrıca, hayatımın her aşamasında desteklerini esirgemeyen değerli aileme ve kıymetli eşime şükranlarımı sunarım.

Ferda DAL

Aralık, 2015

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER.....	2
2.1. Dolaşım Sistemi	2
2.1.1. Kalbin yapısı ve çalışma prensibi.....	2
2.1.2. Kalp sesleri	4
2.1.2.a. Birinci kalp sesi (S1)	4
2.1.2.b. İkinci kalp sesi (S2).....	5
2.1.2.c. Üçüncü kalp sesi (S3).....	5
2.1.2.d. Dördüncü kalp sesi (S4)	6
3. MATERYAL ve YÖNTEM.....	7
3.1. Materyal.....	7
3.1.1. Veri tabanı	7
3.1.2. Performans ölçümü.....	8
3.2. Yöntem	10
3.2.1. Öznitelik çıkarma	10
3.2.2. Mel frekansı kepstrum katsayıları	10
3.2.2.a. Çerçeveleme	11
3.2.2.b. Pencereleme.....	12
3.2.2.c. Fourier dönüşümü.....	12
3.2.2.d. Önvurgulama	13
3.2.2.e. Mel frekansı analizi	13
3.2.2.f. Ayrık kosinüs dönüşümü	14
3.2.3. Gauss karışım modeli (GKM\GMM)	14

3.2.4. Destek vektör makineleri (DVM).....	17
3.2.4.a. Verileri doğrusal olarak ayrılabilen sınıflandırma.....	17
3.2.4.b. Verileri doğrusal olarak ayrılamayan sınıflandırma.....	20
4. ARAŞTIRMA BULGULARI	22
4.1. GKM ve DVM Kullanılarak Cinsiyet Tahmini.....	22
4.1.1. Gauss karışım modeli (GKM) ile cinsiyet tahmini	22
4.1.1.a. Farklı öznitelik vektörlerine göre GKM ile cinsiyet tahmini	23
4.1.1.b. Farklı GKM karışım sayılarına göre cinsiyet tahmini.....	24
4.1.1.c. Test verisi uzunluğuna göre cinsiyet tahmini	25
4.1.2. Destek vektör makineleri (DVM) ile cinsiyet tahmini.....	25
4.1.2.a. Farklı öznitelik vektörlerine göre DVM ile cinsiyet tahmini	26
4.1.2.b. Çerçeve uzunluğu ve kaydırma miktarına göre DVM ile cinsiyet tahmini...26	
4.1.2.c. MFCC'nin farklı istatistiklerine göre DVM ile cinsiyet tahmini	27
4.1.2.d. C ve g parametrelerine göre DVM ile cinsiyet tahmini	28
4.2. DVM Kullanılarak Yaş Sınıfı Tahmini	29
4.2.1. Farklı öznitelik vektörlerine göre DVM ile yaş sınıfı tahmini.....	29
4.2.2. C ve g parametrelerine göre DVM ile yaş sınıfı tahmini	30
4.2.3. MFCC'nin farklı istatistiklerine göre DVM ile yaş sınıfı tahmini	30
4.2.4. Çerçeve uzunluğu ve kaydırma miktarına göre DVM ile yaş sınıfı tahmini....	31
5. SONUÇ	33
KAYNAKLAR	34
ÖZGEÇMİŞ	36

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

η	Eşik değeri
N_e	Hatalı sınıflandırılan kişi sayısı
b	Eğilim değeri(sapma miktarı)
b_i	Gauss bileşen yoğunluğu
C	Düzenleme parametresi
c_i	Standart sapma
g	Gamma parametresi
H_k	Model bileşenleri
K	Çekirdek fonksiyonu
L	Olabilirlik oranı
M	Karışım sayısı
$Melc(k)$	Mel Frekans Katsayıları
m_0	Erkekler için karışım sayısı
m_1	Bayanlar için karışım sayısı
N	Toplam kişi sayısı
P	Performans ölçümü
p_i	Karışım ağırlık parametresi
T	Eğitim vektörleri sayısı
X	Eğitim vektörleri
x	Rastgele değişken vektörü
x_i	Destek vektörü
y_i	Sınıflandırma etiket vektörü
z_k	Öznitelik vektörü
μ_i	Ortalama vektör
ξ	Gevşeklik parametresi (yapay değişken)
Σ_i	Kovaryans matris
$W(n)$	Hamming Pencere fonksiyonu

$x(k)$	Logaritmik enerji çıkışı
α	Larangian çarpanı
ω	Ağırlık vektörleri

Kısaltmalar

DVM	Destek Vektör Makineleri
EM	Beklentinin Maksimumlaştırılması
FFT	Fourier Dönüşümü
GKM	Gauss Karışım Modeli
MFCC	Mel Frekansı Kepstrum Katsayıları
S1	Birinci Kalp Sesi
S2	İkinci Kalp Sesi
S3	Üçüncü Kalp Sesi
S4	Dördüncü Kalp Sesi

ŞEKİLLER DİZİNİ

Şekil 2.1. Kalbin iç yapısı	3
Şekil 2.2. Kalbin kasılması (Sistol)	4
Şekil 2.3. Kalbin gevşemesi (Diyastol)	4
Şekil 2.4. Normal kalp sesi örneği	5
Şekil 3.1. Yaş sınıfına göre veri tabanındaki kişi sayısı dağılımı	7
Şekil 3.2. Cinsiyete göre veri tabanındaki kişi sayısı dağılımı	8
Şekil 3.3. Önerilen yöntemin genel yapı blok diyagramı	9
Şekil 3.4. MFCC özniteliklerinin çıkarılma işleminin blok diyagramı	11
Şekil 3.5. Çerçeve numarası ile gösterilmiş kalp sesi örneği	12
Şekil 3.6. Mel frekans süzgeç öbeği	14
Şekil 3.7. M karışım sayılı Gauss karışım yoğunluğu gösterimi	16
Şekil 3.8. İki sınıflı problem için doğrusal olarak ayrılabilen verileri sınıflandırma	18
Şekil 3.9. İki sınıflı problem için doğrusal olarak ayrılamayan verileri sınıflandırma	20

ÇİZELGELER DİZİNİ

Çizelge 4.1. Farklı öznitelik vektörlerine göre GKM ile sistemin performansı	24
Çizelge 4.2. Farklı Gauss karışım sayısına göre sistemin performansı	24
Çizelge 4.3. Test verisi uzunluğuna göre sistemin performansı	25
Çizelge 4.4. Farklı öznitelik vektörlerine göre DVM ile sistemin performansı	26
Çizelge 4.5. Farklı çerçeve uzunluğu ve kaydırma miktarına göre DVM ile sistemin performansı (10+E öznitelik vektörü kullanılmıştır).....	27
Çizelge 4.6. Farklı MFCC istatistiklerine göre DVM ile sistemin performansı.....	28
Çizelge 4.7. Farklı C ve g parametrelerine göre DVM ile sistemin performansı	29
Çizelge 4.8. Farklı öznitelik vektörlerine göre sistemin performansı.....	30
Çizelge 4.9. Farklı C ve g parametrelerine göre sistemin performansı	30
Çizelge 4.10. Farklı MFCC istatistiklerine göre sistemin performansı	301
Çizelge 4.11. Farklı çerçeve uzunluğu ve kaydırma miktarına göre sistemin performansı	31

1. GİRİŞ

Hücreler yaşamlarını sürdürebilmek için vücutlarındaki her bir hücrenin oksijen ve besin ihtiyaçlarını karşılamaya ve bunun sonucunda oluşan artık maddeleri uzaklaştırmaya ihtiyaç duyarlar. Bu ise dolaşım sistemimiz sayesinde gerçekleştirilir. Dolaşım sistemimizi kan, damarlar ve kalp oluşturur ve bu yapılar sayesinde tüm vücut organları arasında madde iletimi sağlanır. Kan, hücrelerimize madde taşınmasını sağlar. Damarlar, kanın hücrelere iletimini sağlar. Kalp ise kan için pompa görevi görerek kanın damarlarda akmasını ve hücrelere iletilmesini sağlar. Bu esnada kalpte meydana gelen seslere de kalp sesi adı verilir. Kalp sesi, kalp kapakçıklarının açılıp kapanması ve kanın hareketi esnasında meydana gelen değişimler sonucu oluşur.

Bu tez çalışmasında bireylere ait olan kalp sesleri, cinsiyet tahmini ve yaş sınıfı tahmini işlemlerini gerçekleştirmek için kullanılmaktadır. Bu işlemi gerçekleştirmek için makine öğrenme tekniklerinden Gauss Karışım Modeli (GKM) ve Destek Vektör Makineleri (DVM) kullanılmaktadır.

Hazırlanan tez kapsamında yazılımlar için MATLAB programından faydalanılır. Ayrıca makine öğrenme tekniklerinden GKM ve DVM kullanılarak cinsiyet tahmini yapılır ve sonuçlar kıyaslanır. Yaş sınıfı tahmini işleminde ise DVM kullanılır. Bu işlemler dört aşamadan oluşmaktadır. İlk aşamada cinsiyet tahmini için ikili sınıflandırma (bayan ve erkek), yaş sınıfı tahmini için üçlü sınıflandırma (genç, orta yaşlı ve yaşlı) gerçekleştirilir. İkinci aşamada bireylerin eğitim ve test amaçlı kullanılacak olan iki farklı kalp sesi dosyası ile öznitelik çıkarma işlemi gerçekleştirilir. Üçüncü aşamada çıkarılan bu öznitelikler kullanılarak makine öğrenme teknikleri yardımıyla modelleme yapılır ve eğitim işlemleri gerçekleştirilir. Son olarak test işlemi ile bireylerin bayan ya da erkek olduğuna ve genç, orta yaşlı ya da yaşlı olduğuna karar verilir ve sistemin performansı ölçülür.

2. KURAMSAL TEMELLER

2.1. Dolařım Sistemi

Hücreler yaşamlarını sürdürebilmek için beslenme, solunum ve boşaltım gibi faaliyetleri gerçekleştirirler. Dolařım sistemi, vücudumuzdaki her bir hücrenin oksijen ve besin ihtiyacını karşılamak; bunun sonucunda meydana gelen artık maddeleri (karbondioksit ve amonyak) uzaklařtırmak için bir araya gelmiř organlar sistemidir.

Dolařım sistemini oluřturan yapılar sayesinde, tüm vücut organları arasında madde iletimi saęlanır. Dolařım sistemimizi kan, damarlar ve kalp oluřturur. Kan, sıvı olan bir karışımdır ve hücrelerimize madde tařınması iřlemini gerçekleştirir. Damarlar bu karışımın hücrelere iletilmesini saęlar. Kalp ise kanın damarlarda akması ve hücrelere iletilmesi için pompa görevi görür. Dolařım sistemi kan yoluyla hücrelere oksijen ve besin tařır, mikroplara karşı vücudu korur ve hücrelerde oluřan artık maddelerin vücuttan dıřarı atılmasını saęlayan organlara ulařtırır.


2.1.1. Kalbin yapısı ve çalışma prensibi

Kalp, özel bir tip çizgili kas olan kalp kasından oluřan ve içi boş, ön taraftan arka kısmına doęru sıkıřık bir koni gibidir. Dolařım sisteminin temel unsuru olarak çalışan ve etrafındaki organların çalışmalarını engellemeden kasılıp gevşeyerek kan pompalayan ve hücrelerdeki kirli kanı toplayan bir organdır. Kalp, göęüs boşluęunda iki akcięer arasında göęüs kemięinin hemen arkasında yer alır (Hatipoęlu 2015).

Kalp, dakikada ortalama 60 ile 80 arasında deęiřen bir hızla çarpar. Aęırlıęı ve büyüklüęü yař, cinsiyet ve vücut ölçüsüne göre deęiřir ve yaklaşık olarak her bir bireyin yumruęu büyüklüęündedir.


Kalbin temel görevi, küçük dolaşım (kanın akciğerlere gidip gelmesi) ve büyük dolaşım (kanın bedene dağılması) sistemine kan pompalamaktır. Kan, hücreleri ve organları dolaşp oksijeni buralara bıraktıktan sonra kalbe döner ve tekrar oksijen almak için akciğerlere pompalanır ve oksijenli olarak kalbe geri döner.

Kalp, içi boş bir organdır ve septum adı verilen bir duvar ile yukarıdan aşağıya doğru ikiye bölünür. Sağ taraf kirli kanla, sol taraf ise temiz kanla doludur. Her iki tarafta da iki ayrı odacık bulunur. Yani kalp iki altta iki üstte olmak üzere dört odacıktan (boşluktan) oluşur ve bunlar sıkıştıkları zaman kanı itme gücüne sahip kaslardan oluşur. Bu kasların kalınlığı ise odacığın görevine göre değişir. Üst kısımda bulunan ve toplardamarların açıldığı boşluklara kulakçık (atrium), alt kısımda bulunan ve kanı vücudumuza pompalayan boşluklara karıncık (ventrikül) adı verilir. Kulakçıklar ile karıncıklar arasında kapakçıklar bulunur ve ayrıca karıncıklar ile karıncıklardan çıkan damarlar arasında da kapakçıklar bulunur. Bu kapakçıklar kanın tek yönlü akışını sağlar. Sağ kulakçık ve sağ karıncık arasında üçlü kapakçık (triküspit kapak) bulunurken, sol kulakçık ve sol karıncık arasında ikili kapakçık (mitral kapak) bulunur (Koz 2015). Şekil 2.1’de kalbin iç yapısı gösterilmiştir.




Şekil 2.1. Kalbin iç yapısı (Anonymous 2015)

Kalbin çalışması, sağ kulakçığın üst kısmında yer alan sinoatrial düğümün elektriksel uyarısı ile başlar, kulakçık ve karıncıkların kasılıp gevşemesi ile devam eder. Kulakçık ve karıncıklar birbirine ters çalışır, yani biri kasılırken diğeri gevşeme durumuna geçer. Bu da kanın itici gücünü oluşturur. Kasılma (sistol) anında her bir odacık, içindeki kanı pompalarken gevşeme (diyastol) anında içi kan ile dolar (Phua *et al.* 2008). Şekil 2.2 ve Şekil 2.3'te sırasıyla kalbin kasılma ve gevşemesi gösterilmiştir.



Şekil 2.2. Kalbin kasılması(Sistol)
(Anonymous 2015)



Şekil 2.3. Kalbin gevşemesi (Diyastol)
(Anonymous 2015)

2.1.2. Kalp sesleri

Kalbin çalışması esnasında kalpte bulunan kapakçıklarının açılıp kapanması ve kanın kardiyovasküler sistemde hareketi esnasındaki değişimler sonucu meydana gelen seslere kalp sesleri denir (Say 2002). Normalde kalpte S1 ve S2 olmak üzere iki ses duyulur. Ayrıca S3 ve S4 diye isimlendirilen anormal (patolojik) kalp sesleri de vardır.


2.1.2.a. Birinci kalp sesi (S1)

Kulakçıkların uyarılmasının sonunda karıncıkların uyarılmasının başında meydana gelir ve kapakçıkların kapanmasından dolayı meydana gelen türbülans nedeniyle oluşur. Sistol evresinin başlangıcında oluşur (Liang *et al.* 1997). Normal kalpte 'lub dub'

şeklinde iki ses duyulur. Bunlardan ‘lub’ birinci kalp sesini, ‘dub’ ise ikinci kalp sesini gösterir. S1 duyulan en yüksek sestir, süresi 50-100 ms, frekansı ise 30-100 Hz arasındadır (Debbal 2014).

2.1.2.b. İkinci kalp sesi (S2)

Karıncıkların uyarılması sonunda, semilunar kapakların (aort ve pulmoner kapakçıkları) kapanması ve kulakçık- karıncık (atrioventriküler-triküspid ve mitral) kapakçıkların açılması ile diyastol evresinin başlangıcında oluşur (Say 2002). Dub diye duyulan S2’nin süresi 25-50 ms, frekansı ise 100-200 Hz arasında değişmektedir (Debbal 2014).



Şekil 2.4. Normal kalp sesi örneği

Şekil 2.4’te de görüldüğü gibi S1, S2’den daha alçak frekanslı, daha uzun süreli, daha şiddetli ve keskin bir karakterdir (Ali *et al.* 2015).

2.1.2.c. Üçüncü kalp sesi (S3)

Karıncıkların kanla dolmasından sonra aşırı basınç oluşması durumunda duyulan sestir. ‘Di’ şeklinde duyulur, yumuşak ve hafiftir. Kimi zaman sağlıklı bireylerde de S2’den sonra duyulur.

2.1.2.d. Dördüncü kalp sesi (S4)


S1’den hemen önce ‘ti’ olarak duyulur ve diyastol evresinde yer alır. S4, bireylerde meydana gelen normal olmayan durumlarda (koroner arterdeki bir hastalık, atrioventriküler yetmezlik gibi) duyulan seslerdir.

3. MATERYAL ve YÖNTEM


3.1. Materyal

3.1.1. Veri tabanı

Deneysel çalışmalarımızda kullanılan veri tabanı, literatürde de kullanılan veri tabanı ile aynıdır (Spadaccini and Beritelli 2013). Ayrıca kullanılan veri tabanı uzun yıllar boyunca alınan ölçümler sonucu oluşturulmuştur. Veri tabanında 49'u bayan olmak üzere toplam 205 kişiye ait kalp sesi dosyası bulunmaktadır. Her bir bireye ait eğitim ve test aşamasında kullanılmak üzere iki farklı kalp sesi dosyası vardır. Ayrıca veri tabanı kişilerin sıra numarası, cinsiyeti, doğum yılı ve kaydın alındığı yıl bilgilerini de içermektedir. Dosya içerisindeki kalp sesi verileri programa tanıtıldıktan sonra Mel Frekansı Kepstrum Katsayıları (MFCC), enerji, logaritmik enerji ve MFCC'nin farklı istatistikleri gibi öznitelik setleri kullanılarak kişilere ait cinsiyet ve yaş sınıfı tahmini makine öğrenme tekniklerinden olan Gauss Karışım Modeli (GKM) ve Destek Vektör Makineleri (DVM) yardımıyla gerçekleştirilmiştir. Şekil 3.1 ve Şekil 3.2'de veri tabanındaki kişilerin sırasıyla yaş sınıfı ve cinsiyete göre dağılımları gösterilmektedir.



Şekil 3.1. Yaş sınıfına göre veri tabanındaki kişi sayısı dağılımı



Şekil 3.2. Cinsiyete göre veri tabanındaki kişi sayısı dağılımı

3.1.2. Performans ölçümü


Cinsiyet ve yaş sınıfı tanıma işlemi gerçekleştirilirken sistemin amacı, test edilen kişinin hangi sınıfa ait olduğunu bulmaktır. Cinsiyet tanıma işleminde bayan ve erkek olmak üzere iki farklı sınıf varken; yaş sınıfı tanıma işleminde genç, orta yaşlı, yaşlı olmak üzere üç farklı sınıf vardır. Uygulanan tanıma sistemi ile cinsiyet tanımada bahsedilen kişinin bayan ya da erkek olduğuna, yaş sınıfı tanımada ise genç, orta yaşlı ya da yaşlı olduğuna makine öğrenme yöntemleri yardımıyla karar verilir. Bizim yaptığımız çalışmalarda da yaygın olarak kullanılan makine öğrenme tekniklerinden Gauss Karışım Modeli (GKM) ve Destek Vektör Makineleri (DVM) kullanılarak cinsiyet ve yaş sınıfı tahmin işlemleri gerçekleştirilerek elde edilen verilerden performans ölçümü yapılır. N_e hatalı sınıflandırılan kişi sayısı ve N toplam kişi sayısı kabul edildiğinde performans ölçümü, doğru tahmin edilen kişi sayısının toplam kişi sayısına oranı dikkate alınarak yapılmakta ve aşağıdaki gibi hesaplanmaktadır (Dal vd 2015).

$$N_e = \text{Hatalı sınıflandırılan kişi sayısı} \quad (3.1)$$

$$N = \text{Toplam kişi sayısı}$$

$$P = \left(\frac{N - N_e}{N} \right) * 100 \quad (3.2)$$

Şekil 3.3'te hedeflenen amaç doğrultusunda yaptığımız çalışmaları gösteren blok diyagramı verilmiştir. Burada ilk olarak eğitim ve test verisinden öznitelik çıkarma işlemi gerçekleştirilir. Daha sonra eğitim verisinden çıkarılan öznitelik vektörleri kullanılarak GKM ve DVM yardımıyla modelleme yapılır ve son olarak da oluşturulan bu modeller kullanılarak test işlemi gerçekleştirilerek test edilen kişinin bayan ya da erkek; genç, orta yaşlı ya da yaşlı olduğuna karar verilir..



Şekil 3.3. Önerilen yöntemin genel yapı blok diyagramı

3.2. Yöntem

3.2.1. Öznitelik çıkarma


Kalp seslerinden kişi tanıma işlemi yapılırken kalp sesi sinyalinin tamamının kullanılması yerine, bu sinyalden kişi tanıma işlemi daha iyi yapabilecek özniteliklerin çıkarılması gerekmektedir. Öznitelik çıkarma işlemi, kalp sesi sinyalinde var olan fazla ve gürültü bileşenlerinin çıkarılarak, sınıflandırma işlemi için faydalı özelliklerin belirlenmesi ile yapılır (Dal vd 2015). Belirlenen bu faydalı özelliklerin her biri hazırlanan programlar üzerinde ayrı ayrı denenir ve en faydalı sonuçları veren özellikler öznitelik olarak kullanılır. Bu çalışmada kullanılan öznitelikler literatürde özellikle konuşma tanımada kullanılan Mel Frekansı Kepstrum Katsayıları (MFCC), enerji, logaritmik enerji ve bu özniteliklerin delta (türev) değerleri ile MFCC'nin farklı istatistikleridir. Bu öznitelikler kullanılarak daha faydalı olanları tespit edilir.

Öznitelik çıkarma işleminde ilk olarak her bir bireye ait olan eğitim ve test amaçlı kullanılacak olan her iki kalp sesi sinyali çerçevelere (frame) bölünür. Çerçevelere bölme işleminde sinyal belli uzunluktaki parçalara ayrılır ve her bir parçanın belirli bir miktar örtüşmesine izin verilir. Son olarak her bir çerçevenin öznitelik değeri hesaplanır, öznitelik çıkarma işlemi tamamlanır ve bu öznitelikler cinsiyet ve yaş sınıfı tahmini işleminde kullanılır.

3.2.2. Mel frekansı kepsrum katsayıları

Mel Frekansı Kepstrum Katsayıları, konuşma ve konuşmacı tanıma sistemlerinde tercih edilen ve en faydalı sonucu veren, bu nedenle yaygın olarak kullanılan öznitelik çıkarma işlemidir. Bunun nedeni ise, insan kulağının frekans seçiciliği taklit edilerek konuşma ve konuşmacıları ayırt edebilecek değerleri ve özellikleri ortaya çıkarması, aynı zamanda değişimlerden ve ses dalga yapısından daha az etkilenmesidir (Eskidere and Ertaş 2009).


Öznitelik çıkarma işlemi, hem eğitim hem test aşamasında her bir birey için ayrı ayrı yapılır ve birkaç aşamadan oluşur. Bu aşamalar Şekil 3.4'te sırası ile gösterilmiştir.



Şekil 3.4. MFCC özniteliklerinin çıkarılma işleminin blok diyagramı

3.2.2.a. Çerçeveleme

Ses sinyalleri küçük zaman aralıklarında daha kararlıdır. Bu nedenle çerçeveleme işlemi ile ses sinyalleri daha küçük parçalara ayrılır ve ses sinyallerinin karakteristiklerinin belirli bir boyutta sabit kalması amaçlanır. Ses sinyalleri genellikle değişen uzunluklarda çerçevesiz ve en verimli aralık yapılan çalışmalarla belirlenir. Ayrıca her bir çerçeveye belirli bir miktar örtüşme uygulanır. Yani bir önceki çerçeve sonundaki işaret ile bir sonraki çerçeve başındaki işaret bir miktar örtüşür. Böylece çerçeve sonundaki işaretin önemini kaybetmesi önlenir ve bir çerçeveden diğerine geçişin yumuşak olması sağlanır. Yine örtüşme miktarının belirlenmesi, değişik uzunlukların denenmesi ile elde edilen sonuçların değerlendirilmesi ile gerçekleştirilir. (Gelegin ve Bolat 2011). Şekil 3.5'te çerçeveleme işlemi uygulanmış kalp sesi sinyali gösterilmektedir.



Şekil 3.5. Çerçeve numarası ile gösterilmiş kalp sesi örneği

3.2.2.b. Pencereleme

Mel Frekansı Kepstrum Katsayılarını elde etmek için çevreleme işleminden sonra yapılan ikinci işlem pencerelemedir. Pencereleme işlemi, bir çerçeveden diğerine geçerken oluşacak olan süreksizliklerin ortadan kaldırılmasını amaçlar ve böylece ses sinyalinin orta bölgeleri güçlendirilirken kenar bölgeleri zayıflatılır.

Pencereleme çeşitleri Dikdörtgen, Barlett, Kaiser, Hamming, Hanning, ve Blackman gibi pencereleme çeşitleri vardır. Bizim bu çalışmada kullandığımız pencereleme çeşidi Hamming Pencere'dir. N her çerçevedeki konuşma örneği sayısını göstermek üzere bu pencereyi tanımlayıcı fonksiyon aşağıdaki gibidir (Karasartova 2011).

$$W(n) = 0.54 - 0.46 * \cos(2 * \pi * \frac{n}{N-1}) \quad N - 1 \geq n \geq 0 \quad (3.3)$$

3.2.2.c. Fourier dönüşümü

Bu kısımda her bir çerçevenin Hızlı Fourier Dönüşümü alınarak sinyalin frekans bileşenleri tespit edilir. Yani hangi frekansta ne şiddette bir titreşim olduğunu göstererek karmaşık sinyalleri anlaşılır hale getirir.

3.2.2.d. Önvurgulama


Yüksek frekanslar çeşitli sebeplerle zayıflatılabilir. Önvurgulama işlemi ile bu zayıflatma önlenmektedir.

3.2.2.e. Mel frekansı analizi

Frekansları insan kulağı doğrusal olmayan bir şekilde algılar. Frekanslar ise 1 kHz'e kadar doğrusal, 1 kHz'in üzerindeki değerlerde ise logaritmiktir. Mel frekans birimi, insan kulağının frekansı algılamasını taklit etme mantığı ile çalışır. f , frekansı göstermek üzere mel frekansına dönüşüm için aşağıdaki formül uygulanır.

$$\text{Mel}(f) = 2595 * \log((f/700) + 1) \quad (3.4)$$

Bir frekansı mel frekansına dönüştürmek için bant geçiren filtre kullanılır. Bu bant geçiren filtre % 50 oranında birbirini kesen üçgenlerden oluşan filtredir. Birbirini kesen üçgen filtrenin aralıkları ve bant genişliği sabittir ve mel frekansı aralığına bağlıdır (Karasartova 2011). Bir önceki adımda elde edilen sinyal, bu üçgen filtre ile çarpılır ve her bir üçgen altında kalan enerji hesaplanır. Enerji hesaplama işlemi filtre içerisinde kalan genlik değerleri ve bunlara karşılık gelen filtre kazançları ile çarpılır, çarpım sonucu elde edilen değerlerin toplanması ile gerçekleşir. Hesaplanan enerjinin de logaritması alınır. Şekil 3.6'da üçgen filtre yapısı gösterilmektedir.



Şekil 3.6. Mel frekans süzgeç öbeği (Karasartova 2011)

3.2.2.f. Ayrık kosinüs dönüşümü

Bu aşamda sinyalin ayrık fourier dönüşümü alınarak sinyal frekans uzayından tekrar zaman uzayına geçirilir. Böylece keprstrum katsayıları elde edilir. Mel Frekansı Kepstrum Katsayıları ($Melc(k)$) aşağıdaki denklemde ifade edilmektedir.

$$Melc(k) = \sum_{k=1}^{20} x(k) * \cos\left(i * \frac{k-1}{2} * \frac{\pi}{20}\right) \quad k = 1, 2, 3, \dots M \quad (3.5)$$

Bu ifadede M, keprstrum katsayılarının sayısını ve $x(k)$, $k= 1, 2, 3, \dots 20$ için filtrenin logaritmik enerji çıkışı gösterir.

3.2.3. Gauss karışım modeli (GKM)

Gauss Karışım Modeli (GKM), kişi tanımda kullanılan en yaygın modellerden biridir. GKM, her biri birer Gauss olasılık dağılımıyla ifade edilen bileşenlerin ağırlıklandırılmış toplamından oluşur. Eğer bir sınıfa ait örnekler, sadece bir olasılık yoğunluk fonksiyonu şeklinde formülize edilemiyorsa Gauss Karışım Modeli kullanılır

ve yaklaşık olarak modellenenebilir. Bu çalışmada da cinsiyet tahmini için oluşturulan her bir sınıf GKM ile yaklaşık olarak modellenmiştir. x , D-boyutlu rastgele değişken vektörü olarak kabul edildiğinde Gauss karışım yoğunluğu aşağıdaki gibi ifade edilir (Reynolds and Rose 1995; Reynolds *et al.* 2000).

$$p(x|\lambda) = \sum_{i=1}^M p_i b_i(x) \quad (3.6)$$

Bu eşitlikte M toplam karışım sayısını, p_i karışım ağırlığı ve $b_i(x)$ Gauss bileşen yoğunluğu göstermektedir. Her bir bileşen yoğunluğu ise aşağıdaki gibi ifade edilir.

$$b_i(x) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i) \right\} \quad (3.7)$$

Burada;

- Σ_i , kovaryans matrisi
- μ_i , ortalama vektörü
- $|\Sigma_i|$ ise kovaryans matrisinin determinant işlemini ifade etmektedir.


Karışım ağırlıkları toplamı 1'e eşit olacak şekilde sınırlandırılır ve aşağıdaki gibi ifade edilir.

$$\sum_{i=1}^M p_i = 1 \quad (3.8)$$

Yoğunluk model parametreleri olan p_i , μ_i , Σ_i kullanılarak her bir bireyin GKM'si λ olarak ifade edilir.

$$\lambda = \{p_i, \mu_i, \Sigma_i\} \quad i = 1, 2, 3 \dots M \quad (3.9)$$

Şekil 3.7’de Gauss karışım yoğunluğunun elde edilmesi gösterilmiştir.



Şekil 3.7. M karışım sayılı Gauss karışım yoğunluğu gösterimi

Bu tez kapsamında cinsiyet tahmini yaparken öncelikle bireyler bayan ve erkek olmak üzere ikili sınıfa ayrılır ve bireylere ait kalp sesleri kullanılarak öznitelik çıkarma işlemi gerçekleştirilir. Daha sonra GKM ile cinsiyet tahmini işlemi gerçekleştirilir. Cinsiyet tahmini gerçekleştirilirken ise GKM’deki bileşenlere ait parametrenin tahmini için maksimum benzerlik tahmini kullanılır. Amaç ise eğitim verilerinden $p(x|\lambda)$ ’yi maksimum yapacak model parametrelerini bulmaktır. T adet eğitim vektörlerinin bir dizisi için $X = \{x_1, x_2, \dots, x_T\}$ olmak üzere Gauss karışım olasılığı denklem 3.10’da gösterildiği gibi ifade edilir.

$$p(X|\lambda) = \prod_{t=1}^T p(x_t|\lambda) \quad (3.10)$$

Fakat yukarıda ifade edilen denklem λ parametrelerinin doğrusal olmayan bir fonksiyonudur ve direkt maksimum yapılamaz. Maksimum yapılabilmesi için beklentinin maksimumlaştırılması (EM) algoritması kullanılarak λ parametrelerine göre en büyük değerler bulunur (Dempster *et al.*1977). EM algoritması kullanılırken ilk olarak bir ‘ λ ’ modeli ile başlanır ve yeni bir model ‘ λ' ’ tahmin edilir. Yani $p(X|\lambda') > p(X|\lambda)$ değerine bakılır ve maksimum değer bulununcaya kadar devam edilir.

Bu şekilde her bir sınıfa ait model parametreleri oluşturularak modeller test işlemine hazır hale getirilir.

3.2.4. Destek vektör makineleri (DVM)

Destek Vektör Makineleri (DVM), regresyon ve sınıflandırma problemlerinin çözümü için Vapnik tarafından geliştirilmiştir (Vapnik 1995). DVM, son zamanlarda geliştirilen istatistiksel ve denetimli öğrenme yaklaşımına dayalı makine öğrenme tekniklerinden biridir (Venkatesan and Devi 2012, 2013). İlk olarak doğrusal ve iki sınıflı verilerin sınıflandırılması ile başlamış, doğrusal olmayan ve çok sınıflı verilerin sınıflandırılması şeklinde geliştirilmiştir. DVM'nin çalışma prensibi, iki farklı sınıfı en iyi şekilde ayırabilecek karar fonksiyonunun tahmin edilmesine dayanır. Yani iki farklı sınıfı birbirinden en iyi şekilde ayırabilecek hiper-düzlemin oluşturulmasına dayanır (Vapnik 1995). Bu hiper-düzlem iki sınıfa ayırma işlemi gerçekleştirir. Hiper-düzleme en yakın olan ve aynı zamanda iki sınıfın birbirine en yakın örneklerine destek vektörleri adı verilir. Burada hedeflenen her bir sınıfın destek vektörlerini belirleyip, hiper-düzleme olan uzaklıklarını maksimum hale getirip iki sınıfın ayrımını en iyi şekilde gerçekleştirmektir.


DVM, regresyon problemlerinde de kullanılmakta ve bu problemlere çözüm sunmaktadır. DVM ile regresyon analizinde temel fikir, eğitim verilerini modelleyerek gerçeğe yakın bir şekilde yansıtan, doğrusal ayırıcı fonksiyonu bulmaktır.

DVM ile sınıflandırma işleminde karşılaşılabilecek iki durum, verilerin doğrusal olarak ayrılabilen yapıda olması ve verilerin doğrusal ayrılamayan bir yapıda olmasıdır. Sonraki kısımda bu iki durum açıklanmaktadır (Yakut vd 2014).

3.2.4.a. Verileri doğrusal olarak ayrılabilen sınıflandırma

DVM, iki sınıflı doğrusal olarak ayrılabilen bir problemi kolay bir şekilde sınıflandırma yaparak çözebilmektedir. Bu problemi iki sınıfı birbirinden en iyi şekilde ayırabilecek

hiper-düzlem oluşturmasıyla çözer ve bu hiper-düzlem iki sınıfın destek vektörlerinin tam ortasından geçer. Aşağıdaki şekilde doğrusal olarak ayrılabilen verilerin hiper-düzlem oluşturulması ile ayrılma işlemi gösterilmiştir.



Şekil 3.8. İki sınıflı problem için doğrusal olarak ayrılabilen verileri sınıflandırma

İki sınıflı doğrusal ayrılabilen verilerin DVM ile sınıflandırılması 2. dereceden denklemin çözümü ile yapılmaktadır. $i=1,2,3,\dots,k$ olmak üzere k adet örnekten oluşan eğitim verisi $\theta = \{x_i, y_i\}$ şeklinde gösterilebilir (Kavzoğlu ve Çölkesen 2010). İki sınıfı en iyi şekilde ayırabilecek hiper-düzleme ait eşitsizlikler aşağıdaki şekilde gösterilirler.

$$\begin{aligned} \omega x_i + b &\geq 1 & y_i &= 1 \\ \omega x_i + b &\leq -1 & y_i &= -1 \end{aligned} \quad (3.11)$$

Burada;

- $x_i \in R^N$ (N boyutlu uzayda) destek vektörlerini,
- $y_i = \{+1, -1\}$ ise ait oldukları sınıf etiketlerini,
- b eğilim değerini,

- ω ise ağırlık vektörünü göstermektedir.

İki sınıfı birbirinden en iyi şekilde ayırabilecek hiper-düzlemin belirlenebilmesi için bu düzlemin sınırlarını belirleyen ve paralel olan iki hiper-düzlem belirlenmelidir. Bu hiper-düzlemleri destek vektörleri belirler ve bu vektörler hiper-düzlemlerin üzerinde bulunurlar. Bu düzlemler aşağıdaki denklem ile ifade edilirler.

$$\omega x_i + b = \pm 1 \quad (3.12)$$

Optimum hiper-düzlem sınırının maksimum olabilmesi için $\|\omega\|$ değerinin minimum olması gerekmektedir. Dolayısıyla aşağıdaki işlem uygulanarak en iyi hiper düzlem oluşturulabilir.

$$\text{Min}[\frac{1}{2} \|\omega\|^2] \quad (3.13)$$

3.11’de bulunan iki eşitsizlik aşağıdaki gibi tek bir eşitsizlikte birleştirilebilir.

$$y_i(\omega x_i + b) \geq 1 \quad \forall i \text{ için} \quad (3.14)$$


Optimum hiper-düzlemin bulunmasında Lagrange çarpanlarından faydalanılır ve 3.14’teki denklem Lagrange denklemi kullanılarak çözülebilir. Bu ifadede α_i Lagrange çarpanlarını göstermektedir.

$$L(\omega, b, a) = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^k \alpha_i y_i (\omega x_i + b) + \sum_{i=1}^k \alpha_i \quad (3.15)$$

x_i noktalarını ayırabilen en iyi hiper-düzlemi bulmak için gerekli olan karar fonksiyonunu aşağıdaki gibi ifade edilir.

$$f(x_i) = \text{sign}(\omega x_i + b) = \begin{cases} 1 & \text{eğer } y_i = 1 \\ -1 & \text{eğer } y_i = -1 \end{cases} \quad (3.16)$$

3.2.4.b. Verileri doğrusal olarak ayıramayan sınıflandırma



Şekil 3.9. İki sınıflı problem için doğrusal olarak ayıramayan verileri sınıflandırma

Doğrusal eşitliklerle hiper-düzlemin belirlenememesi durumunda doğrusal olmayan hiper-düzlem oluşturulmaya çalışılır. Bu ise kernel (çekirdek) fonksiyonları olarak bilinen doğrusal olmayan fonksiyonların kullanılmasıyla daha yüksek boyutlu bir uzayda çalışarak doğrusal olmayan dönüşümler yapılması ile sağlanır (Ayhan ve Erdoğan 2014). Şekil 3.9’da bu durum gösterilmiştir.

Literatürde en sık kullanılan Kernel fonksiyonları;

- Doğrusal fonksiyonlar,
- Polinomial fonksiyonlar,
- Radyal tabanlı fonksiyonlar,
- Sigmoid fonksiyonlarıdır.

Verileri doğrusal olarak ayıramayan sınıflandırma yaparken eğitim verilerinin bir kısmı belirlenen en uygun hiper-düzlemin diğer tarafında kalmasından dolayı meydana gelen problemleri çözmek için pozitif bir yapay değişken (ξ_i) tanımlanır. Ayrıca maksimum

sınır ve minimum hata arasındaki dengeyi sağlayan, pozitif değerler alan bir düzenleme parametresi (C) de tanımlanarak doğrusal ayrılamayan verilerin optimizasyon problemi aşağıda verilmiştir.

$$\text{Min } \left[\frac{1}{2} \|\omega\|^2 \right] + C \sum_{i=1}^r \xi_i \quad (3.17)$$

Buna bağlı sınırlamalar ise $\forall i$ için, $\xi_i \geq 0$ ve $i=1,2,3,\dots,N$ için aşağıda gösterilmiştir.

$$y_i(\omega y_i + b) \geq 1 - \xi_i \quad (3.18)$$

Destek vektör makineleri, doğrusal olarak ayrılamayan sınıflandırma problemleri için matematiksel olarak $\varphi(x_i) \cdot \varphi(x_j) = K(x_i, x_j)$ şeklinde ifade edilen bir kernel fonksiyonu yardımıyla çok boyutlu uzayda çalışılarak doğrusal ayırım yapılabilir. $z = \varphi(x)$ dönüşüm parametresi, K kernel çekirdek fonksiyonu olmak üzere çok boyutlu uzaya geçilerek doğrusal ayırım yapabilen karar fonksiyonu aşağıdaki gibi tanımlanabilir.

$$f(x_i) = \text{sign}(\omega z + b) = \text{sign} \left[\frac{1}{2} \sum_{i=1}^{N_s} y_i \alpha_i K(x_i, x) + b \right] \quad (3.19)$$

4. ARAŞTIRMA BULGULARI

Hazırlanan tez kapsamında, bireylere ait kalp sesleri kullanılarak kişilere ait cinsiyet ve yaş sınıfı tahminini gerçekleştirecek deneysel çalışmalar yapılmıştır. Bu deneysel çalışmalarda makine öğrenme tekniklerinden, Gauss Karışım Modeli (GKM) ve Destek Vektör Makineleri (DVM)'den yararlanılmıştır. Cinsiyet tahmini yapılırken ilk aşamada bireyler bayan ve erkek diye adlandırılan iki farklı sınıfa ayrılmıştır, daha sonra Matlab programı kullanılarak cinsiyet tanıma işlemi iki farklı makine öğrenme tekniğiyle gerçekleştirilmiştir. Yaş sınıfı tanıma işleminde ise ilk olarak bireyler genç (<30), orta yaşlı (30-50) ve yaşlı (>50) olmak üzere üç farklı yaş grubuna göre sınıflandırılmış ve Matlab programı kullanılarak yaş sınıfı tanıma işlemi Destek Vektör Makineleri (DVM) yöntemiyle gerçekleştirilmiştir. Böylece her bir bireyin hangi cinsiyet ve yaş sınıfına ait olduğu tahmin edilebilmiştir.

4.1. GKM ve DVM Kullanılarak Cinsiyet Tahmini

4.1.1. Gauss karışım modeli (GKM) ile cinsiyet tahmini

Yapılan çalışmalar doğrultusunda ilk aşamada, cinsiyet tahmini yapabilmek için bayan ve erkek olmak üzere ikili sınıflandırma yapılır. Daha sonraki aşamada bireylere ait kalp seslerinden her bir bireye ait öznitelikler çıkarılır. Belirlenen bu öznitelikler kullanılarak GKM ile yaklaşık modeller üretilir, bu istatistiksel modeller eğitilir ve son olarak da test etme işlemi gerçekleştirilerek, test edilen kişinin bayan ya da erkek olduğuna karar verilir. Bu karar verme işlemi için olabilirlik oranı testi uygulanır.

Herhangi bir kişiye ait öznitelikler z_k olmak üzere, bu kişinin cinsiyetini belirleyecek optimum karar, z_k 'ya ait olabilirlik oranının $\Lambda(z_k)$ belli bir eşik değeri ile karşılaştırılması sonucu elde edilir. Bu eşik değeri ise birkaç değerin denenmesi sonucu elde edilen en verimli değere göre belirlenir. Burada;

H_0 : Ölçülen kalp sesleri bir erkeğe aittir (Erkek),

H_1 : Ölçülen kalp sesleri bir erkeğe aittir değildir (Bayan)

η : Eşik değeri,

$p(z_k|H_0)$, $p(z_k|H_1)$: H_0 ve H_1 hipotezlerinin şartlı olasılık yoğunluk fonksiyonlarını göstermek üzere optimum karar mekanizması ;

$$\Lambda(z_k) = \frac{p(z_k|H_0)}{p(z_k|H_1)} \begin{cases} \geq \eta & \text{ kabul } H_0 \\ < \eta & \text{ ret } H_0 \end{cases} \quad (4.1)$$

formülü ile ifade edilir (Neyman and Pearson 1933).

4.1.1.a. Farklı öznitelik vektörlerine göre GKM ile cinsiyet tahmini

Gauss karışım modelini kullanarak yapılan kalp sesi ile cinsiyet tanıma işleminde yukarıda gerçekleştirilen aşamalardan sonra farklı öznitelik vektörleri kullanılarak önerilen sistemin performansı incelenmiştir ve optimum sonuçlar elde edilinceye kadar farklı öznitelikler denenmeye devam edilmiştir.

Kullanılan öznitelikler aşağıda sıralanmaktadır:

- ❖ MFCC: Mel Frekanslı Kepstrum Katsayıları (Bu özneliğin farklı dereceleri (13,15,30,50...) denenmiştir ve tablolarda optimum sonuç gösterilmiştir.)
- ❖ Z: 0. Kepstrum
- ❖ E: Her bir çerçeve için hesaplanan enerji
- ❖ Δ : İlgili özneliğin türev değeri

Örneğin;

13+Ed (13+13 Δ +E+E Δ) : 13+E özneliğine bunların türevinin eklenmesi ile oluşturulan öznitelik vektörüdür.

Çizelge 4.1. Farklı öznitelik vektörlerine göre GKM ile sistemin performansı

Öznitelik Tipi	Doğruluk (%)
13+13 Δ +E+E Δ +Z+Z Δ	74,46
13+E+Z	79,55
50+E	80,6
13+E	82,5
30+E	83,6

*Karışım sayıları: $m_0 = 4$ ve $m_1 = 4$ kullanılmıştır.

Çizelge 4.1’de karışım sayısı erkekler için $m_0 = 4$ ve bayanlar için $m_1 = 4$ kullanıldığında elde edilen doğruluk değerleri verilmiştir. En iyi sonucun 30+E özniteliği kullanıldığında elde edildiği görülmektedir.

4.1.1.b. Farklı GKM karışım sayılarına göre cinsiyet tahmini

Cinsiyet tahmininde, bayan ve erkeklere ait farklı Gauss karışım sayıları kullanılmıştır. Farklı karışım sayıları kullanmadaki amaç, optimum cinsiyet tanıma işleminin yapıldığı doğru karışım sayılarını elde etmektir. Bu amaçla aynı öznitelik vektörleri için farklı karışım sayıları kullanılarak çalışmalar tekrarlanmış, optimum karışım sayısı elde edilmeye çalışılmış ve sistemin performansı incelenmiştir. m_0 erkekler için karışım sayısı, m_1 bayanlar için karışım sayısını göstermek şartıyla sistemin performansı Çizelge 4.2’de gösterilmiştir.

Çizelge 4.2. Farklı Gauss karışım sayısına göre sistemin performansı

m_0	m_1	Doğruluk (%)
14	7	79,4
2	2	81,6
8	6	83,1
4	2	84,6
6	4	84,7
5	3	87,7

*Öznitelik: 30 + E kullanılmıştır.

Çizelge 4.2’de bayan ve erkekler için farklı karışım sayılarında elde edilen sonuçların karışım sayısı ile doğru orantılı değişmediği görülmektedir. Bir miktar artıp daha sonra azaldığı görülmektedir. Ayrıca en iyi sonuçların erkekler için karışım sayısının 5 seçildiği, bayanlar için ise 3 seçildiği durumlarda elde edilmiştir.

4.1.1.c. Test verisi uzunluğuna göre cinsiyet tahmini

Kalp sesinden cinsiyet tanıma işleminde, yukarıdaki denemelerden sonra test edilecek kişiden elde edilen verinin uzunluğunun (süresinin) önerilen sistemin başarısına etkisi gözlemlenmiştir. Bu amaçla aynı karışım sayısı ve aynı öznitelik vektörü kullanılarak 1, 2, 3 ve 5 s süreli test verileri kullanılmış ve sonuçlar Çizelge 4.3’te gösterilmiştir.

Çizelge 4.3. Test verisi uzunluğuna göre sistemin performansı

<i>Süre(s)</i>	1	2	3	5
Doğruluk(%)	82,2	83,6	84,7	87,7

*Öznitelik: 30+E, $m_0 = 5$, $m_1 = 3$ kullanılmıştır.

Çalışmalar sonucunda süre arttıkça sistemin performansının arttığı da görülmektedir ve 5 s süreli veri için %87,7 olan en verimli sonuç elde edilmiştir.

Ayrıca veri tabanındaki kişilerden eşit sayıda bayan ve erkek seçilerek yapılan çalışmalar, tüm kişiler kullanılarak yapılan çalışmalara göre daha iyi sonuç vermiştir (49 bayan, 49 erkek seçilmiştir).

4.1.2. Destek vektör makineleri (DVM) ile cinsiyet tahmini

Uygulamanın bu aşamasında DVM ile hazırlanan yazılım ile cinsiyet tanıma işlemi yapılmaktadır. DVM ile cinsiyet tanıma işleminde, ilk olarak bireyler bayan ve erkek diye adlandırılan iki sınıfa ayrılır. Daha sonra bireylere ait kalp seslerinden öznitelik çıkarma işlemi gerçekleştirilir. Belirlenen bu öznitelikler kullanılarak DVM ile

modelleme işlemi gerçekleştirilir. Oluşturulan bu modeller eğitilir ve son olarak test etme işlemi gerçekleştirilir. Test işlemi sonucunda test edilen bireyin bayan ya da erkek olduğuna karar verilir.

4.1.2.a. Farklı öznitelik vektörlerine göre DVM ile cinsiyet tahmini

Destek Vektör Makineleri ile yapılan kalp sesi sinyalinin cinsiyet tanıma işleminde farklı öznitelik vektörleri kullanılarak sistemin performansı incelenmiş ve optimum sonucun alındığı öznitelik vektörü tespit edilmiştir.

C düzenleme parametresi ve g gamma parametresi (kernel (çekirdek) fonksiyonlarında kullanılan çekirdek parametrelerinden birisi) olmak üzere sırasıyla 2 ve 0,05 seçilerek farklı öznitelik vektörlerinin denenmesi sonucu elde edilen sistemin performansı Çizelge 4.4'te gösterilmiştir. En iyi sonucun 10+E öznitelik vektörünün kullanılmasıyla elde edildiği görülmektedir.

Çizelge 4.4. Farklı öznitelik vektörlerine göre DVM ile sistemin performansı

Öznitelik Tipi	Doğruluk (%)
30+30 Δ +E+E Δ +Z+Z Δ	78
30+30 Δ +E+E Δ	85
50+E	84
30+E	87,75
10+E	88,77

*Bu tabloda C=2 ve g=0,05 çerçeve uzunluğu=128, kaydırma miktarı =70 olan değerler kullanılmıştır.

4.1.2.b. Çerçeve uzunluğu ve kaydırma miktarına göre DVM ile cinsiyet tahmini

Çalışmamızın bu aşamasında cinsiyet tahmininde, kalp sesi sinyalinin çerçeve uzunluğu (frame length) ve kaydırma miktarı (shift length) değiştirilerek sistemin performansı incelenmiş, optimum sonucun alındığı çerçeve uzunluğu ve kaydırma miktarı tespit edilmiştir.

Çizelge 4.5'te çerçeve uzunluğu ve kaydırma miktarına göre optimum değerin sırasıyla 155 ve 100 kullanıldığı durumda elde edildiği görülmüştür (155/100).

Çizelge 4.5. Farklı çerçeve uzunluğu ve kaydırma miktarına göre DVM ile sistemin performansı

Çerçeve Uzunluğu	Kaydırma Miktarı	Doğruluk(%)
200	50	85,71
256	100	86
128	70	88,77
128	110	89,79
150	100	90,81
155	100	91,83

* Bu tabloda 10+E öznitelik vektörü, C=2, g=0,05 kullanılmıştır.

4.1.2.c. MFCC'nin farklı istatistiklerine göre DVM ile cinsiyet tahmini

Yapılan çalışmanın bu aşamasında MFCC'nin farklı istatistiklerinin bir ya da birkaçı birlikte kullanılarak sistemin performansı incelenmiş ve optimum değerin hangi istatistiklerin bir arada kullanılması ile elde edildiği tespit edilmiştir. Optimum değeri veren istatistikler uç uca eklenerek tek bir vektör haline getirilerek, Destek Vektör Makineleri yardımıyla modelleme yapılmıştır. Daha sonra eğitim ve test işlemleri uygulanarak cinsiyet tahmini gerçekleştirilmiştir.

MFCC'nin kullanılan özellikleri,

- ❖ Mean MFCC : MFCC öznitelik vektörünün ortalamasıdır.
- ❖ Std MFCC : MFCC öznitelik vektörünün standart sapmasıdır.
- ❖ Max MFCC : MFCC öznitelik vektörünün maksimum değeridir.
- ❖ Min MFCC : MFCC öznitelik vektörünün minimum değeridir.
- ❖ Skewness MFCC : MFCC öznitelik vektörünün çarpıklık değeridir.
- ❖ Kurtosis MFCC : MFCC öznitelik vektörünün basıklık değeridir.
- ❖ Median MFCC : MFCC öznitelik vektörünün medyan değeridir.

❖ **Range MFCC** : MFCC öznitelik vektörünün en büyük ve en küçük değeri arasındaki farktır.

Çizelge 4.6’da MFCC’nin farklı istatistikleri bir arada kullanılarak elde edilen sonuçlar gösterilmektedir. Tablo incelendiğinde en iyi sonuç olan 93,87’nin MFCC’nin mean, std, max, skewness, kurtosis, range vektörlerinin sırası ile uç uca eklenmesi ile oluşturulan vektörün kullanılması sonucunda elde edildiği görülür.

Çizelge 4.6. Farklı MFCC istatistiklerine göre DVM ile sistemin performansı

Özellikler	Öznitelik Boyutu	Doğruluk (%)
Mean + std + skewness + kurtosis	44	85,71
Mean + std + min + skewness + kurtosis + median	66	88,77
Mean + kurtosis + median + range	44	87,75
Mean + std + min + skewness	44	89,79
Mean + std + max+ skewness + kurtosis + range	66	91,83

* Bu tabloda 10+E öznitelik vektörü, C=2, g=0,05, çerçeve uzunluğu 155, kaydırma miktarı 100 olan değerler kullanılmıştır

4.1.2.d. C ve g parametrelerine göre DVM ile cinsiyet tahmini

Yapılan çalışmalarda cinsiyet tahmininde C düzenleme parametresi, g gamma parametresi değerleri değiştirilerek sistemin performansı incelenmiştir. Farklı C ve g parametrelerini kullanarak, optimum cinsiyet tanıma işleminin yapıldığı C ve g değerleri bulunmuştur.

Çizelge 4.7’de C ve g parametrelerine göre sistemin performansı gözlemlenmiş ve en iyi sonucun C ve g parametrelerinin sırasıyla 3 ve 0,03 olduğu durumlarda olduğu gözlemlenmiştir.

Çizelge 4.7. Farklı C ve g parametrelerine göre DVM ile sistemin performansı

C	g	Doğruluk(%)
1	0,02	77,55
3	0,05	87,75
2	0,05	91,83
3	0,03	93,87

*Bu tabloda 10+E öznitelik vektörü, çerçeve uzunluğu 155, kaydırma miktarı 100 olan değerler kullanılmıştır

4.2. DVM Kullanılarak Yaş Sınıfı Tahmini

Yapılan çalışmanın bu kısmında 205 kişiye ait kalp sesleri kullanılarak yaş sınıfı tahmini yapılmaktadır. Öncelikle veri tabanındaki kişiler genç(<30), orta yaşlı (30-50) ve yaşlı (>50) olmak üzere üç farklı sınıfa ayrılır. Daha sonra bireylere ait kalp sesi sinyallerinden her bir bireye ait öznitelikler çıkarılır. Belirlenen bu öznitelikler kullanılarak DVM ile modelleme işlemi gerçekleştirilir ve oluşturulan modeller eğitilir. Son olarak test etme işlemi gerçekleştirilir ve her bir bireyin yaş sınıfına karar verilir.

4.2.1. Farklı öznitelik vektörlerine göre DVM ile yaş sınıfı tahmini

Destek Vektör Makineleri ile yapılan kalp sesi sinyalinden yaş sınıfı tahmini işleminde farklı öznitelik vektörleri kullanılarak sistemin performansı incelenmiş ve optimum sonucun alındığı öznitelik vektörü tespit edilmiştir.

Çizelge 4.8 incelendiğinde en iyi sonucun 14+E öznitelik vektörü kullanıldığında elde edildiği görülmektedir.

Çizelge 4.8. Farklı öznitelik vektörlerine göre sistemin performansı

Öznitelik Tipi	Doğruluk (%)
10+E	72,72
10+10Δ+E+EΔ	73,23
12+E	73,23
50+E	73,73
14+E	74,74

*Bu tabloda C=4, g=0,03, çerçeve uzunluğu 200, kaydırma miktarı 100 olan değerler kullanılmıştır.

4.2.2. C ve g parametrelerine göre DVM ile yaş sınıfı tahmini

Yapılan çalışmanın bu aşamasında yaş sınıfı tahmininde C düzenleme parametresi, g gamma parametresi değerleri değiştirilerek sistemin performansı incelenmiş ve performansın optimum değerindeki C ve g değerleri bulunmuştur ve Çizelge 4.9’da elde edilen sonuçlar gösterilmiştir.

Çizelge 4.9. Farklı C ve g parametrelerine göre sistemin performansı

C	g	Doğruluk (%)
5	0,06	73,23
2	0,06	73,73
3	0,03	74,24
4	0,03	74,74
5	0,03	75,25

*Bu tabloda 14+E öznitelik vektörü, çerçeve uzunluğu 200, kaydırma miktarı 100 olan değerler kullanılmıştır.

Çizelge 4.9’da en iyi sonucun C ve g parametrelerinin sırasıyla 5 ve 0.03 olduğu durumlarda elde edildiği görülmektedir.

4.2.3. MFCC’nin farklı istatistiklerine göre DVM ile yaş sınıfı tahmini

Yapılan çalışma kapsamında son olarak MFCC’nin farklı istatistiklerinden biri ya da birkaçı birlikte kullanılarak sistemin performansı incelenmiş ve optimum değer hangi istatistiklerin bir arada kullanılması sonucu elde edildiği tespit edilmiştir. Bu amaçla

tespit edilen istatistiklerin birinin kullanılması ile optimum sonuç elde ediliyorsa direkt o istatistik vektörü kullanılır. Ancak birkaç istatistik kullanılarak optimum sonuç elde edilmesi durumunda bu vektörler sırasıyla uç uca eklenerek tek bir vektör oluşturulur ve bu vektör kullanılarak DVM metoduyla modelleme yapılır. Daha sonra eğitim ve test işlemleri uygulanarak yaş sınıfı tahmini gerçekleştirilir.

Çizelge 4.10’de MFCC’nin farklı istatistikleri bir arada kullanılarak elde edilen sonuçlar gösterilmektedir. Tabloyu incelendiğinde en iyi sonuç olan 78.28’in; mean, std, max, skewness, median, range istatistik vektörlerinin sırası ile uç uca eklenerek ve tek bir vektör haline getirilmesi ile oluşturulan vektörünün kullanılması durumunda elde edildiği görülmektedir.

Çizelge 4.10. Farklı MFCC özelliklerine göre sistemin performansı

Özellikler	Öznitelik Boyutu	Doğruluk (%)
Mean+std+max+min+skewness+ kurtosis+ median+range	120	74,24
Mean + std +min + skewness + median + range	90	75,25
Mean+std+max+min+skewness+median+range	105	76,76
Mean + std + max+ skewness + median + range	90	78,28

*Bu tabloda Çerçeve uzunluğu 200, kaydırma miktarı 100 olan değerler kullanılmıştır.

4.2.4. Çerçeve uzunluğu ve kaydırma miktarına göre DVM ile yaş sınıfı tahmini

Yapılan çalışmada yaş sınıfı tahmininde kalp sesi sinyalinin çerçeve uzunluğu (frame length) ve kaydırma miktarının (shift length) sistemin performansına etkisi incelenmiş ve optimum sonucun alındığı çerçeve uzunluğu ve kaydırma miktarı gözlemlenmiştir.

Çizelge 4.11 incelendiğinde çerçeve uzunluğu ve kaydırma miktarının sırasıyla 200 ve 100 olduğu durumda optimum sonucun alındığı görülmektedir (200/100).

Çizelge 4.11. Farklı çerçeve uzunluğu ve kaydırma miktarına göre sistemin performansı

Çerçeve Uzunluğu	Kaydırma Miktarı	Doğruluk(%)
70	30	73,73
250	90	75,25
155	100	76,26
128	70	77,77
200	100	78,28

5. SONUÇ

Bu tez kapsamında veri tabanındaki kişilere ait kalp sesleri kullanılarak cinsiyet ve yaş sınıfı tahmini yapılmakta ve yeni bir biyometrik tanıma yöntemi önerilebileceği görülmektedir. Ayrıca gelecekte henüz doğmamış bebeklerin anne karnında iken cinsiyetlerinin tespit edilebilmesinde kullanılabileceği öngörülmektedir.

Cinsiyet tahmini yaparken makine öğrenme tekniklerinden GKM ve DVM kullanılarak iki ayrı MATLAB yazılımı ile modelleme yapıp eğitim ve test aşamalarından geçirildikten sonra cinsiyet tahmini yapılmıştır. Daha sonra DVM ve GKM kullanılarak elde edilen sonuçlar karşılaştırılmış ve DVM kullanılarak elde edilen sonuçların daha iyi olduğu tespit edilmiştir. Yaş sınıfı tahmini yaparken makine öğrenme tekniklerinden DVM kullanılarak modelleme yapılmış, eğitim ve test işlemlerinden sonra yaş sınıfına karar verilmiştir.

GKM kullanılarak yapılan cinsiyet tahmini işleminde öznitelik olarak 30+E kullanılan durumda, DVM kullanılarak yapılan cinsiyet tahmini işleminde ise 10+E özniteliği ile optimum sonuçların elde edildiği görülmüştür. Yaş tahmini işleminde ise 14+E özniteliği ile optimum sonuçlara ulaşılmıştır.

GKM kullanılarak yapılan cinsiyet tahmini işleminde, bayan ve erkek karışım sayılarının sırasıyla 5 - 3 seçildiğinde ve test verisi uzunluğu artırıldığında sistemin performansının iyileştiği görülmüştür. DVM kullanılarak yapılan cinsiyet tahmini işleminde ise çerçeveleme uzunluğunun 155, kaydırma miktarının 100, C ve g değerlerinin ise sırasıyla 3 - 0,03 seçildiği durumlarda optimum sonuçlar elde edilmiştir.

DVM kullanılarak yapılan yaş sınıfı tahmini işleminde ise, çerçeveleme uzunluğunun 200, kaydırma miktarının 100, C ve g değerlerinin ise sırasıyla 5 - 0,03 seçildiği durumlarda optimum sonuçlara ulaşılmıştır.

GKM kullanılarak gerekleřtirilen cinsiyet tahmini iřleminde sistemin bařarısı %87,75 iken DVM kullanılarak elde edilen sistemin bařarısı %93,87 olarak bulunmuřtur. Yař sınıfı tahmini iřleminde ise sisteminin performansı %78,28 olarak elde edilmiřtir.

KAYNAKLAR

- Ali, H., Ahmad T., and Khan S., 2015. Heart Sound Signal and Segmentation Based on Improved Shannon Energy Envelopogram Using Adaptive Windows. Asia Link Conference, http://www.utdallas.edu/hussnain.ali/publications/AsiaLinkConference_Jakarta_2007.pdf (02.11.2015).
- Anonymous, 2015. <http://www.servier.com/Powerpoint-image-bank> (25.10.2015).
- Ayhan, S., ve Erdoğan, Ş., 2014. Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 9(1), 175-198.
- Dal, F., Ozbek, I., ve Coşgun, S., 2015. Kalp Sesi ile Cinsiyet Tanıma. Signal Processing and Communications Applications Conference (SIU), İnönü Üniversitesi.
- Dempster A. P., Laird N. M. and Rubin D. B., 1977. Maximum-Likelihood from Incomplete Data Via The EM Algorithm. Journal of the Royal Statistical Society. Series B (Methodological), 39(1), 1-38.
- Debbal, S., 2014. Model of Differentiation between Normal and Abnormal Heart Sounds in Using the Discrete Wavelet Transform. Journal of Medical and Bioengineering, 3 (1), 5-11.
- Devi, G., and Venkatesan, P., 2013. Least Squares Support Vector Regression for Spirometric Forced Expiratory Volume (FEV1) Values. International Journal, (3).
- Eskidere, Ö., and Ertas F., 2009. The Effects of Filter Frequency Scale Variability on Speaker Identification Performance. Journal of Engineering and Natural Sciences, 27, 197-207.
- Gelegin, İ., ve Bolat, B., 2011. Ayrık Kelime Tabanlı Bir Konuşma Sistemiyle Bilgisayar Kontrolü. Elektrik-Elektronik ve Bilgisayar Sempozyumu, Fırat Üniversitesi, Elazığ.
- Hatipoğlu, E., 2015. Dolaşım Sistemi. <http://www.dicle.edu.tr/Contents/2e1cb4b7-0b23-41dc-9698-bad3d0f2f69c.pdf> (05.11.2015).
- Karasartova, S., 2011. Metinden Bağımsız Konuşmacı Tanıma Sistemlerinin İncelenmesi ve Gerçekleştirilmesi. Y. Lisans Tezi, Fen Bilimleri Enstitüsü, Ankara Üniversitesi, Ankara.
- Kavzoğlu, T., ve Çölkesen İ., 2010. Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. Harita Dergisi , 154, 73-82.
- Koz, M., 2015. Kalp Dolaşım Sistemi Fizyolojisi ‘Kardiyovasküler Sistem Fizyolojisi’. <http://80.251.40.59/sports.ankara.edu.tr/koz/ana-fiz/dolasim.fizyoloji.pdf> (06.11.2015).
- Liang, H., Lukkarinen, S., and Hartimo, I., 1997. Heart Sound Segmentation Algorithm Based on Heart Sound Envelopogram. ", Computers in Cardiology, Vol. 24, 105-108
- Neyman, J., and Pearson, E., 1933. On The Problem of The Most Efficient Tests of Statistical Hypotheses. Philos Trans Roy Soc, A 231, 289–337.

- Phua, K., Chen, J., Dat, T., and Shue, L., 2008. Heart Sound As A Biometric. *Pattern Recognition*, 41(3), 906-919.
- Reynolds , D., Quatieri, T., and Dunn, R., 2000 . Speaker Verification Using Adapted Gaussian Mixture Models. *Digital Signal Processing*, 10, 19-41.
- Reynolds, D., and Rose, R., 1995 . Robust Text-Independent Speaker Identification Using Gaussian Mixture Speaker Models. *IEEE Transaction On Speech And Audio Processing*, 3(1), 72-83.
- Say, Ö., 2002. Kalp Seslerinin Analizi ve Yapay Sinir Ağları ile Sınıflandırılması. Y.Lisans Tezi, Fen Bilimleri Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul.
- Spadaccini A., and Beritelli F., 2013 "Performance Evaluation of Heart Sounds Biometric Systems on An Open Dataset", *Digital Signal Processing (DSP)*, 18th International Conference on , p 1-5, 1-3.
- Vapnik,V., 1995. *The Nature of Statistical Learning Theory*, S pringer.
- Venkatesan, P., and Devi, G., 2012. Proximal Support Vector Machine for Disease Classification. *International Journal of Scienceand Technology*, 2(1), 2224-3577.
- Yakut, E., Elmas, B., ve Yavuz, S., 2014. Yapay Sinir Ağları Ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(1) , 139-157.

ÖZGEÇMİŞ

Ferda DAL 1989 yılında Erzurum merkezde doğdu. İlk, orta ve lise öğrenimini Erzurum'da tamamladı. 2008-2012 yıllarında Atatürk Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümünü okudu ve 2012 yılında mezun oldu. Aynı yıl Atatürk Üniversitesi Fen Bilimleri Enstitüsü'nde Elektrik-Elektronik Anabilim Dalı, Haberleşme Bilim Dalı'nda Yüksek Lisans yapmaya başladı.